



**UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO**



**CENTRO UNIVERSITARIO UAEM TEXCOCO**

**SISTEMA PARA PRE-DIAGNOSTICAR EL CÁNCER DE PIEL  
TIPO MELANOMA.**

**T E S I S**

**QUE PARA OBTENER EL GRADO DE:  
MAESTRO EN CIENCIAS DE LA COMPUTACIÓN.**

**PRESENTA:  
JUAN JOSÉ RANGEL CORTÉS.**

**TUTOR ACADÉMICO:  
DR. EN I.S. JOSÉ SERGIO RUIZ CASTILLA.**

**TUTORES ADJUNTOS:  
DR. EN C. ADRIÁN TRUEBA ESPINOSA.  
DR. EN C. JAIR CERVANTES CANALES.**

**TEXCOCO, ESTADO DE MÉXICO, DICIEMBRE DE 2019.**

## DEDICATORIAS Y AGRADECIMIENTOS

*A mí familia!*

*A mis profesores!*

*A mis amigos!*

*A todos*

*¡GRACIAS!*

# ÍNDICE

CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1. Planteamiento del Problema. ....	1
1.2. Justificación. ....	2
1.2.1. Objetivo general. ....	2
1.2.2. Objetivos específicos.....	2
1.3. Hipótesis. ....	2
CAPÍTULO 2. ESTADO DEL ARTE .....	3
2.1 Cáncer de piel. ....	3
2.2 Datos clínicos sobre el cáncer de piel. ....	4
2.3 El método de la lista de siete puntos para detección de melanoma. ....	6
2.4 Estructuras dermoscópicas del melanoma. ....	7
3.3 Verificación <i>ABCD</i> .....	10
2.5 El cáncer de piel y la inteligencia artificial.....	13
2.6 Trabajos sobre el cáncer de piel y técnicas de clasificación.....	16
2.6.1 Mahbod.....	16
2.6.2 Hao .....	17
2.6.3 Yang .....	19
2.6.4 Shoieb.....	19
2.6.5 Codella .....	21
2.6.6 Dorj.....	22
2.6.7 Liao.....	24
2.6.8 Georgakopoulos .....	25
2.6.9 Grzesiak-Kopec.....	28

2.6.10 Majtner .....	29
2.6.11 Haenssle .....	37
2.6.12 Kawahara.....	39
2.6.13 Moura .....	42
2.6.14 Olivares .....	45
2.6.15 Premaladha.....	46
2.6.16 Yuexiang .....	47
2.6.17 Yu.....	48
2.6.18 Pomponiu .....	49
2.7 Sistemas automatizados más relevantes, para la detección de melanoma. ....	49
2.7.1 MoleMax™ .....	49
2.7.2 DBDermo-Mips / DDAX.....	50
2.7.3 Fotofinder .....	51
2.7.4 DermaGraphix/Mirror .....	51
2.7.5 SIAscopy™ Molemate.....	51
2.7.6 MelaFind® .....	52
2.7.7 Dermoscopix .....	52
2.7.8 MicroDerm .....	53
2.7.9 MoleExpert.....	53
2.7.10 <i>DermAlert</i> ® .....	53
2.7.11 MelApp.....	53
2.7.12 UMSkinCheck.....	53
2.7.13 Molemap.....	54
2.7.14 Melanoscan.....	54
CAPÍTULO 3. PRELIMINARES .....	56

3.1 Inteligencia artificial, aprendizaje automático y aprendizaje profundo.....	56
3.2 Python, Numpy y OpenCV.....	58
3.3 Keras y TensorFlow.....	58
3.4 Tensores.....	59
3.4.1 Scalars (tensores 0D).....	60
3.4.2 Tensor 2D.....	60
3.4.3 Tensores 3D y tensores de dimensiones superiores. ....	60
3.5 Convolución 2D.....	62
3.6 Redes neuronales convolucionales CNN.....	64
CAPÍTULO 4. METODOLOGÍA.....	69
4.1. Técnica 1.....	69
4.2. Técnica 2.....	74
4.3. Técnica 3.....	77
4.8 Técnica 4 explorando más épocas con imágenes más pequeñas .....	79
CAPÍTULO 5. RESULTADOS Y CONCLUSIONES .....	80
5.1 Exportando el modelo y el peso a una Raspberry Pi 3 Model B.....	81
5.2 Interfaz del sistema.....	92
CAPÍTULO 6. TRABAJOS FUTUROS.....	97
Referencias .....	98

## ÍNDICE DE FIGURAS

Figura 1 Ejemplo de lesiones con red de pigmento, en la izquierda se ve una red de pigmentos típicos, mientras que en la derecha se ve una res de pigmentos atípicos [29].	7
Figura 2 Tanto en la fotografía izquierda como en la derecha se observan ejemplos de lesiones con puntos y glóbulos [29].	8
Figura 3 En la fotografía izquierda se observa un ejemplo de lesiones con vetas regulares, mientras que en la fotografía de la derecha se observa un ejemplo con vetas irregulares [29].	8
Figura 4 En la fotografía de la izquierda se observa una lesión de velo azul-blanquecino en etapa inicial, mientras que en la fotografía de la derecha se observa una lesión de velo azul-blanquecino más avanzada [29].	9
Figura 5 En la fotografía de la izquierda se puede observar un nevu con hipopigmentación, mientras que en la fotografía de izquierda se observa un melanoma con hipopigmentación [29].	9
Figura 6 En la fotografía de la izquierda se observa un nevo simétrico, mientras que en la fotografía de la derecha se observa un melanoma no simétrico [30].	10
Figura 7 En la fotografía izquierda se observan bordes regulares (benignos) mientras que en la fotografía derecha se observan bordes are irregular (melanoma maligno [30].	11
Figura 8 En la fotografía de la izquierda se muestra una lesión con un tono / color uniforme (benigno), mientras que en la fotografía de la derecha se observan dos o más tonos / colores desiguales (melanoma maligno) [30].	11
Figura 9 Factores comunes en imágenes dermatoscópicas. Primera fila: una imagen normal, una esquina oscura y bello de la piel, de izquierda a derecha, respectivamente. Segunda fila: artefacto de colores, marcador de regla y marcador de tinta [6].	14
Figura 10 A la izquierda se muestra una imagen con bello, a la derecha la imagen ya procesada ya sin bello [8].	15
Figura 11 A la izquierda se observa una imagen no segmentada a la derecha una imagen segmentada [8].	15

Figura 12 Ilustración de LDA utilizada para la identificación de las características más discriminatorias para el conjunto de datos de entrenamiento. Las imágenes de una lesión de melanoma se indican como im_mel y las imágenes de una lesión benigna como img_b. Los valores $f_i$ , donde $i \in \{1, \dots, 4096\}$ son valores característicos derivados de un aprendizaje profundo [15].	32
Figura 13 Evaluación de la precisión de la clasificación (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de entidad reducida que varía de 0 a 200 componentes (eje x) [15].	35
Figura 14 Evaluación de la sensibilidad (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].	35
Figura 15 Evaluación de la especificidad (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].	36
Figura 16 Evaluación de la precisión promedio (eje y) con SVM y k-NN clasificadores con longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].	36
Figura 17 Evaluación del área bajo la curva ROC (eje y) utilizando clasificadores SVM y k-NN con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].	37
Figura 18 La red neuronal multirresolución completamente convolucional de dos vías (o dos tractos) propuesta [17].	40
Figura 19 Resultados de la variación porcentual de los atributos seleccionados para el clasificador MLP [18].	45
Figura 20 Pre procesamiento de imagen [21].	48
Figura 21 Se muestra la herramienta de software Molemax, integrada con sistema propietario, se tomó una captura de pantalla del software. [31].	50
Figura 22 Artificial Intelligence, machine learning y deep learning [32].	56
Figura 23 Imagen rellenada con ceros en los límites [38].	63
Figura 24 Filtro [38].	64
Figura 25 Resultado del filtro para la posición 0,6 [38].	64

Figura 26 Diagrama de flujo básico de una red neuronal convolucional [38].	67
Figura 27 Arquitectura de red para las pruebas.	69
Figura 28 a) Matriz de imágenes sin metadatos. b) Matriz de imágenes con metadatos	70
Figura 29 Gráfica de Acc y Val_acc de la técnica 1 sin metadatos.	72
Figura 30 Gráfica de Loss y Val_loss de la técnica 1 sin metadatos.	72
Figura 31 Gráfica de Acc y Val_acc de la técnica 1 con metadatos	73
Figura 32 Gráfica de Loss y Val_loss de la técnica 1 con metadatos	74
Figura 33 Ejemplo de imágenes sin piel.	75
Figura 34 Gráfica de Acc y Val_acc de la técnica 2 imágenes sin piel.	76
Figura 35 Gráfica de Loss y Val_loss de la técnica 2 imágenes sin piel.	76
Figura 36 Ejemplo de imágenes de la técnica 3	77
Figura 37 Gráfica de Acc y Val_acc de la técnica 3 aumentó de imágenes.	78
Figura 38 Gráfica de Loss y Val_loss de la técnica 3 aumentó de imágenes.	78
Figura 39 Raspberry Pi 3	81
Figura 40 Instalación de opencv, Tensorflow y Keras	88
Figura 41 Prueba de las librerías instaladas para cargar los pesos y modelos.	89
Figura 42 Salida de código de la Figura 41.	90
Figura 43 Fragmento de código de la predicción de melanoma maligno o benigno.	91
Figura 44 Resultado de la predicción de la imagen de un melanoma maligno.	92
Figura 45 Diagrama de casos de uso del sistema	93
Figura 46 Comando para abrir el sistema.	94
Figura 47 Interfaz del sistema	95
Figura 48 Ejemplo de pre diagnóstico del sistema	96



## ÍNDICE DE TABLAS

Tabla 1 Diagnóstico histopatológico y tamaño de 76 lesiones melanocíticas sospechosas de melanoma maligno Diagnóstico histopatológico y tamaño de 76 lesiones melanocíticas sospechosas de melanoma maligno. Se excluyeron las lesiones localizadas en acral u otros sitios especiales, lesiones más de 6 mm, lesiones extirpadas de manera incompleta, o aquellas procesadas con artefactos [25].....	4
Tabla 2 Puntuación de la "regla ABCD" para asimetría, borde, color y estructuras dermatoscópicas [31].....	11
Tabla 3 Valores de TDS para clasificar una lesión en benigna, sospechosa y maligna [31]. .....	13
Tabla 4 Resultados resumidos. M significa melanoma y SK significa queratosis seborreica [6]. .....	17
Tabla 5 Comparación el rendimiento entre DCNN multitarea y GoogleNet [10].....	19
Tabla 6 Resultados de la clasificación de lesiones de melanoma y no melanoma de los datos obtenidos de Dermatology Information System [7]. .....	20
Tabla 7 Resultados de la clasificación de lesiones de melanoma y no melanoma de los datos obtenidos de DermQuest. [7].....	20
Tabla 8 Resultados de la clasificación de melanoma, carcinoma de células basales, eczema e impétigo de los datos obtenidos de DermNet Skin Disease. [7].....	21
Tabla 9 Resultados de rendimiento: melanoma vs atípico y benigno [11].....	22
Tabla 10 Resultados de rendimiento: Melanoma vs atípico [11]. .....	22
Tabla 11 Resultado de la implementación de la clasificación de cáncer de piel [5]. .....	24
Tabla 12 Accuracy de las CNNs usando diferentes modelos pre-entrenados de ImageNet, todas las CNN se entrenaron utilizando las imágenes Dermnet solamente [12]. .....	25
Tabla 13 Utilizando sólo el modelo VGG19. Se prueban en las imágenes OLE , para VGG19 Mejorado, se usa el conjunto de datos refinado [12]. .....	25
Tabla 14 Resultados de clasificación logrados para el problema de clasificación de imágenes de dos clases con datos de entrada aumentados basados en filtro [13]. .....	27
Tabla 15 Resultados de clasificación en el conjunto de datos de validación con datos de entrada RGB [13]. .....	27

Tabla 16 Resultados de clasificación en el conjunto de datos de validación con datos de entrada aumentados basados en filtros [13].....	28
Tabla 17 Resultados para el clasificador Naive Bayes, el bosque aleatorio y K * [14].....	29
Tabla 18 Resultados del empaquetamiento (BAGGIN) aplicado a: el clasificador Naive Bayes, el Bosque aleatorio y el clasificador basado en instancias K * [14].....	29
Tabla 19 Los resultados del voto se aplicaron a: el clasificador Naive Bayes, el Bosque aleatorio y el clasificador basado en instancias K * [14]. .....	29
Tabla 20 Resumen de los resultados de la primer prueba de la primera columna muestra el rendimiento utilizando todas las funciones 4096 (sin LDA), la segunda columna es el valor más alto para la métrica y el clasificador especificados (el más alto), y la tercera columna es el valor máximo para la métrica y el clasificador especificados cuando menos de 200 funciones Se utilizan (los más altos 200). AP significa precisión media y AUC significa área bajo la curva ROC [15].....	34
Tabla 21 Resultado de los experimentos [17]. .....	41
Tabla 22 Resultados de Olivares entre otros para diferentes clasificadores [19].....	46
Tabla 23 Resultados de Premaladha [20]. .....	47
Tabla 24 Comparativa de los sistemas anteriormente descritos. ....	55
Tabla 25 Descripción de conjuntos de datos con y sin metadatos, las imágenes son las mismas.....	70
Tabla 26 Resultados sin metadatos.....	71
Tabla 27 Resultados con metadatos.....	73
Tabla 28 Resultados de imágenes sin piel.....	75
Tabla 29 Resultados de la prueba 3 .....	77
Tabla 30 Comparativa de las tres técnicas con otros trabajos .....	80

## Abstrac

The most common skin cancer is melanoma. Said cancer has increased in multiple parts of the world. Therefore, we worked on the classification of melanomas to support the possible detection of malignant melanomas that cause skin cancer. Convolutional neural networks or (*CNN*) were used for the classification of melanomas in malignant or benign. Images available from International Skin Imaging Collaboration (*ISIC*) were used. Four techniques were applied: 1) Melanomas were classified by adding metadata of age, gender and size of melanoma, within the same matrix of pixels. 2) The images were processed by removing the skin from the lesion. 3) The *CNN* was applied with a size of 300 x 300 pixels and with 2000 images. 4) *CNN* is applied by decreasing the size of the images (100x100 pixels) and the times will be increased up to 1000. Training and validation was carried out in each technique. In the end, each technique was tested with new images not used in training or validation and results were obtained. In the results, a better result was obtained in the fourth technique when more epochs were added.

## Resumen

El cáncer de piel más común es el de tipo melanoma. Dicho cáncer, ha aumentado en múltiples partes del mundo. Por lo anterior, se trabajó en la clasificación de melanomas para apoyar la posible detección de melanomas malignos que causan cáncer de piel. Se utilizaron redes neuronales convolucionales o (*CNN*) por sus siglas en inglés, para la clasificación de los melanomas en malignos o benignos. Se utilizaron imágenes disponibles de International Skin Imaging Collaboration (*ISIC*). Se aplicaron cuatro técnicas: 1) Se clasificaron melanomas añadiendo metadatos de edad, género y tamaño del melanoma, dentro de la misma matriz de píxeles. 2) Se procesaron las imágenes quitando la piel de la lesión. 3) Se aplicó la *CNN* con un tamaño de 300 x 300 píxeles y con 2000 imágenes. 4) Se aplica la *CNN* disminuyendo el tamaño de las imágenes (100x100 píxeles) y se aumentaran las épocas hasta 1000. Se llevó a cabo el entrenamiento y validación en cada técnica. Al final, se probó cada técnica con imágenes nuevas no usadas en el entrenamiento ni validación y se obtuvieron resultados. En los resultados, se obtuvo un mejor resultado en la cuarta técnica cuando se añadieron más épocas.

# CAPÍTULO 1. INTRODUCCIÓN.

El aumento del índice de cáncer es un problema de salud alrededor del mundo, entre los tipos de cáncer más comunes en los Estados Unidos de América, se encuentra el cáncer de piel tipo melanoma, y en México es cada vez más frecuente este tipo de enfermedad. Esto es debido a diferentes factores como, una exposición prolongada a los rayos *UV* o exposición al agua contaminada por arsénico. Debido a esto, se pretende hacer un sistema informático de pre diagnóstico de cáncer de piel tipo melanoma, utilizando visión artificial, y así poder tener una herramienta que detecte esta enfermedad de manera oportuna.

## 1.1. Planteamiento del Problema.

En la Región de las Américas, el cáncer es la segunda causa de muerte. Se estima que 2.8 millones de personas son diagnosticadas cada año y 1.3 millones de personas mueren por esta enfermedad anualmente. Aproximadamente el 52% de los nuevos casos de cáncer ocurren en personas de 65 años o menos, que están en la flor de la vida. Si no se adoptan más medidas, se prevé un incremento a más de 4 millones de nuevos casos y 1.9 millones de defunciones por cáncer para el año 2025. [1]. Los cánceres de piel, hasta los melanomas, pueden curarse casi siempre si se descubren y tratan precozmente [2].

Dentro del Sistema Nacional de Salud en México existen tres niveles de atención: El *primer nivel*, donde se proporcionan los servicios de salud básicos. Son el principal escenario de la salud preventiva y es el nivel en donde se atiende y resuelve 80% de los padecimientos. Es la puerta de entrada al Sistema Nacional de Salud. Desde este nivel se remite, a quien así lo requiera, al segundo o tercer nivel de atención. En el *segundo nivel* se atiende a los pacientes remitidos por los servicios del primer nivel de atención que requieren de procedimientos diagnósticos, terapéuticos y de rehabilitación. El *tercer nivel* de atención es donde se tratan enfermedades de baja prevalencia, de alto riesgo y las enfermedades más complejas. En este se atiende a los pacientes que remiten del *primer y segundo nivel* [3]. El diagnóstico y tratamiento de cáncer de piel debe pasar por el primer y/o segundo nivel y tratado en el tercer nivel

¿Cómo pre-diagnosticar el cáncer en la piel manifestado en melanomas mediante análisis de imágenes digitales?

## 1.2. Justificación.

En la Ciudad de México se recibe 35 por ciento más radiación que en las costas debido a la altitud; sin embargo, al estar en la playa el daño es mayor porque usamos menos ropa. A eso se suma que en los últimos años lo estéticamente “aceptable” es estar bronceado, y por ello la gente pasa más tiempo expuesta a los rayos solares. Por lo anterior el cáncer de piel se ha convertido en un problema de salud pública, no sólo en México, sino en el mundo [4]. El desarrollo de un sistema informático que realice un pre-diagnóstico para el cáncer de piel hará que se pueda dar una detección oportuna para dar acceso quien lo requiera, al segundo y tercer nivel de Sistema Nacional de Salud para su atención.

### 1.2.1. Objetivo general.

Desarrollar algoritmos para pre-diagnosticar cáncer de piel procesando y clasificando imágenes de melanomas en benignos y malignos “

### 1.2.2. Objetivos específicos.

Obtener imágenes de melanomas benignos y malignos para construir un conjunto de datos

Desarrollar un algoritmo para procesar y clasificar las imágenes de melanomas.

Obtener resultados de melanomas malignos para el pre-diagnóstico de cáncer de piel

## 1.3. Hipótesis.

Con un algoritmo que obtenga y analice imágenes digitales se puede determinar si un melanoma en la piel puede ser potencialmente maligno y de esta forma pre-diagnosticar de manera oportuna el cáncer del tipo de piel.

## CAPÍTULO 2. ESTADO DEL ARTE

Se han realizado varios trabajos para poder pre diagnosticar el cáncer de piel, con diferentes técnicas usando inteligencia artificial, en el siguiente apartado de mencionan algunos de ellos.

### 2.1 Cáncer de piel.

El cáncer de piel se ha clasificado en dos grandes grupos: el cáncer de piel no melanoma y el melanoma. De estos dos, el cáncer de piel melanoma maligno es el más letal (responsable del 75% de las muertes por cáncer cutáneo) y frecuente, en todo el mundo cada año se diagnostican cerca 160,000 casos nuevos de melanoma. *La Clínica de Melanoma del Instituto Nacional de Cancerología (INCAN)* reporta que en México ha aumentado este tipo de cáncer, en casi un 500% en los últimos años, es de esperarse que esta tendencia continúe así hasta el año 2020, por lo que, el melanoma será el tipo de cáncer más cotidiano. El melanoma es una enfermedad heterogénea, tiene cuatro tipos histopatológicos: *acral lentiginoso, nodular, extensión superficial y lentigo maligno*. En México el tipo que más ocurre es el *acral lentiginoso* [24].

El diagnóstico de melanoma es difícil, porque se suele confundir con verrugas, hongos, hematomas entre otros [24]. Sin embargo, la precisión de diagnóstico depende significativamente del grado de experiencia de los examinadores y tamaño de las lesiones, como se ha mencionado antes. Las pequeñas lesiones son un desafío de diagnóstico significativo para los médicos [25]. La Tabla 1 muestra el diagnóstico histopatológico y tamaño de 76 lesiones *melanocíticas* sospechosas de melanoma maligno.

Tabla 1 Diagnóstico histopatológico y tamaño de 76 lesiones *melanocíticas* sospechosas de melanoma maligno Diagnóstico histopatológico y tamaño de 76 lesiones *melanocíticas* sospechosas de melanoma maligno. Se excluyeron las lesiones localizadas en *acral* u otros sitios especiales, lesiones más de 6 mm, lesiones extirpadas de manera incompleta, o aquellas procesadas con artefactos [25].

Diagnóstico histopatológico	Tamaño						Total n(%)
	1mm	2mm	3mm	4mm	5mm	6mm	
Nevo unión atípica	-	6	10	4	1	-	21(22.7)
Nevo compuesto atípico	-	-	6	5	4	2	17(22.4)
No diagnóstico	-	5	3	-	2	-	10(13.2)
Nevo compuesto común	-	6	-	3	-	-	9(11.8)
Nevo intradérmico	1	2	3	2	1	-	9(11.8)
Hiperplasia melanocítica lentiginosa atípica con características arquitectónicas	1	3	-	2	1	-	7(9.2)
Lentigo simple	-	1	-	-	1	-	2(2.6)
Melanoma maligno	-	-	1	-	-	-	1(1.3)
Total n(%)	2(2.6)	23(30.2)	23(30.2)	16(21.1)	10(13.2)	2(2.6)	76(100)

## 2.2 Datos clínicos sobre el cáncer de piel.

Reconocer los factores de riesgo es importante tanto como para decisiones de salud pública y para el paciente individual. El factor ambiental más importante es la excesiva exposición al a radiación *UV (ultravioleta)*, en individuos de piel clara, por lo que la latitud es un riesgo, siendo mayor cuanto más próximo al ecuador [26].

Dentro de las variantes clínicas del melanoma podemos encontrar los siguientes tipos:

- *Diseminado superficial*: Es la forma más frecuente (70%) de melanoma en individuos de piel clara, es diagnosticado frecuentemente entre los 30-50 años [26]. Presenta una fase de crecimiento horizontal que puede ir desde seis meses hasta seis años antes del crecimiento vertical [27]. Puede ocurrir de *nov*, o sobre un *nevo* pre-existente. Clínicamente se caracteriza por una mácula asintomática, marrón o negra, con distintas tonalidades de color en la misma lesión, y bordes irregulares (indentaciones). Esta asimetría, ya sea de color o de contorno, es una de las claves para el diagnóstico temprano, aún en lesiones < 5 mm de diámetro. Luego de una fase de lento crecimiento horizontal (radial) limitada a la *epidermis* o a la *dermis papilar* en forma focal, ocurre una rápida fase de crecimiento vertical, manifestada clínicamente como una sobreelevación de la lesión en forma de pápula o nódulo. En algunas ocasiones puede observarse un fenómeno llamado regresión, producto de la interacción entre el



sistema inmune del paciente y el tumor, manifestado como áreas grises, *hipopigmentadas*, dentro de la lesión [26].

- *Nodular*: abarca del 15 al 30% de los casos; es agresivo, típicamente surge de *novo*, afecta principalmente a hombres y se caracteriza por presentar únicamente una fase de crecimiento vertical. Siendo diagnosticado alrededor de la sexta década de la vida Si bien ocurre en cualquier sitio, es más frecuente en tronco, cabeza y cuello [26]. Es el segundo tipo en frecuencia en individuos de piel clara. Se caracteriza por un nódulo negro, rojo o rosado, de aspecto aframbuesado, ocasionalmente ulcerado, sangrante, con crecimiento rápido en el curso de meses [27].
- *Melanoma lentigo*: Ocurre en la séptima década de la vida. En piel crónicamente foto-dañada, comúnmente en la cara, especialmente mejillas y nariz. Comienza usualmente como una mácula amarronada de crecimiento lento, con alguna variación de color y bordes irregulares indentados [26]. Claramente está relacionado con exposición solar; tiene crecimiento radial; la transición al crecimiento vertical marca la transición a melanoma [27].
- *Acral lentiginoso*: abarca del 2% al 8% de los casos en personas blancas y del 35 al 60% en aquéllas de color, es el más común en México y se presenta usualmente en palmas, plantas y la región subungueal. Frecuentemente son planos, de tres centímetros, con bordes irregulares y discromía [27]. Un alto porcentaje de este subtipo es diagnosticado en estudios avanzados, debido posiblemente a la dificultad de diferenciarlos clínicamente de lesiones benignas o traumáticas que ocurren en estos sitios, y a un umbral más elevado para la toma biopsia [26].
- *Melanoma amelánico*: es una variedad de cualquiera de los anteriores, pero no presenta pigmento y usualmente se diagnostica durante la fase de crecimiento vertical [27]. Afortunadamente la mayoría de los melanomas son pigmentados, lo que ayuda en el diagnóstico clínico [26].

- *Melanoma mucoso u ocular*: comprende el 5% de los casos y son difíciles de diagnosticar [27]. El más frecuente es el uveal, al cual sigue el melanoma conjuntival y el de párpados. Estos tumores son más frecuentes en individuos de raza blanca, sometidos a zonas que se consideran predisponentes, como la exposición a sustancias químicas o a luz ultravioleta, así como portadores de lesiones melánicas, como los *nevus displásicos o melanocitosis ocular* entre otros [28].

J.Tarriba et al. [27] indica que el diagnóstico definitivo se basa en la toma de biopsias, las cuales pueden ser escisionales (lesiones < 1.5 centímetros con margen de dos milímetros) o incisionales (> 1.5 centímetros o en zonas de riesgo estético); deben evitarse las biopsias por rasurado debido a que no permiten valorar la profundidad de la lesión.

### 2.3 El método de la lista de siete puntos para detección de melanoma.

En [29] se comenta el método de la lista de los siete puntos, así como las estructuras dermoscópicas para este método:

El método de la lista de siete puntos es un algoritmo, se considera una simplificación del análisis de patrones clásico debido al bajo número de características identificar. Este algoritmo se aplica una vez que la lesión se diagnostica como melanocítica. Fue desarrollado por Argenziano entre otros autores. La lista de verificación de siete puntos es un sistema de puntuación. Este método utiliza siete criterios específicos para el melanoma. Incluye tres criterios principales:

- *Red de pigmentos atípicos.*
- *Velo azul blanquecino.*
- *Patrón vascular atípico*

(Se les atribuyen dos puntos a cada uno de los anteriores.)

Y cuatro criterios menores:

- *Vetas irregulares*
- *Pigmentación irregular*
- *Puntos / glóbulos irregulares*
- *Estructuras de regresión*

(Se les atribuye un punto a cada uno de los anteriores.)


Una puntuación de tres o mayor está asociada con una alta probabilidad de diagnóstico de melanoma en la evaluación de la patología.

## 2.4 Estructuras dermoscópicas del melanoma.

Son estructuras dermoscópicas la *red de pigmentos*, *puntos y glóbulos*, *vetas*, *velo azul-blanquecino*, *estructuras de regresión*, *manchas*, *hipopigmentación* y *estructuras vasculares*. La presencia de características dermoscópicas específicas en diferentes regiones de la misma lesión contribuye a hacer un diagnóstico de lesiones melanocíticas y se llaman patrones locales [29].

*La red de pigmentos* es el patrón local más estudiado; porque es el patrón local más común en las lesiones melanocíticas. Una *red de pigmentos* puede ser típica, cuando el patrón está mallado regularmente, espaciado estrechamente y su distribución es más o menos regular, o *atípica*, caracterizada por una red irregular negra, marrón o gris, distribuida irregularmente a lo largo de la lesión. Una red atípica señala malignidad. La Figura 1 muestra la variabilidad de su apariencia [29].


Figura 1 Ejemplo de lesiones con red de pigmento, en la izquierda se ve una *red de pigmentos típicos*, mientras que en la derecha se ve una *red de pigmentos atípicos* [29].



En los últimos años, varios autores se han centrado en la detección automática de este patrón. Di Leo entre otros autores extendió el trabajo propuesto por Betta entre otros autores para detectar una *red pigmentada atípica*. Primero, detectó la red de pigmentos después el color y las características geométricas fueron extraídas. *El algoritmo C4.5* fue utilizado como clasificador. 173 imágenes de dermatoscopia digital (77 *red de pigmentos atípicos*, 53 *red de pigmentos típicos* y 43 *redes de pigmentos ausentes*) obtenida del Atlas Interactivo de Dermatoscopia fueron utilizados. Se usaron 90 imágenes para entrenamiento y 83 imágenes para pruebas. Se alcanzaron valores de sensibilidad y especificidad superiores al 85% [29].


*Los puntos y glóbulos son redondos u ovalados, de diferentes tamaños, de color negro, marrón o gris. Es una estructura dermatoscópica difícil de discriminar de la red de pigmentos. Esto podría ser la razón por la cual hay tan pocos trabajos en la literatura que se enfoca en su identificación [29]. Algunos ejemplos de lesiones con estas estructuras se muestran en la Figura 2.*

Figura 2 Tanto en la fotografía izquierda como en la derecha se observan ejemplos de lesiones con *puntos y glóbulos* [29].



*Las vetas, son estructuras lineales de color negro pardusco de grosor variable que se encuentran en lesiones benignas y malignas. Por lo general, se colocan en la periferia de una lesión y no están necesariamente conectados a las líneas de la red de pigmentos. Las rayas pueden ser irregulares, cuando están distribuidos de forma desigual (melanoma maligno), o regular (disposición radial simétrica sobre toda la lesión) [29]. Un ejemplo *vetas de regulares e irregulares* se pueden encontrar en la Figura 3.*


Figura 3 En la fotografía izquierda se observa un ejemplo de lesiones con *vetas regulares*, mientras que en la fotografía de la derecha se observa un ejemplo con *vetas irregulares* [29].



Mirzaalian et al. propuso un enfoque de aprendizaje automático para detectar *vetas*. Esta tarea se realiza con un clasificador *SVM* con una base de datos de 99 imágenes dermatoscópicas. Obteniendo un 91% de exactitud [29].

*El velo azul -blanquecino se caracteriza por una pigmentación difusa gris azulada a azul blanquecina. Algunos ejemplos de lesiones que presentan este patrón se muestran en la Figura 4 [29].*

Figura 4 En la fotografía de la izquierda se observa una lesión de *velo azul-blanquecino* en etapa inicial, mientras que en la fotografía de la derecha se observa una lesión de *velo azul-blanquecino* más avanzada [29].




Arroyo entre otros autores también propuso el aprendizaje automático supervisado técnicas para detectar el *velo azul-blanco*. Las características de color se extrajeron de cada píxel individual y el clasificador utilizado fue el algoritmo *C4.5*, que generó un árbol de decisión. Las áreas candidatas seleccionadas en el paso anterior fueron subsecuentemente clasificadas como melanoma con *velo azul-blanco*. Para este propósito, se extrajeron 12 características del área candidata, como área, solidez o elipticidad. Los autores usaron una base de datos que consiste en 887 imágenes. Se seleccionaron 120 imágenes para obtener los datos de entrenamiento, 60 correspondientes a melanoma con patrón de *velo azul-blanquecino* y 60 correspondientes a otros casos. El método logró una sensibilidad de 80.50% y una especificidad de 90.93% [29].

*Las manchas*, son áreas oscuras sin estructura dentro de las lesiones pigmentadas localizadas asimétricamente dentro de una lesión y son indicativos de melanoma maligno [29].

*La hipopigmentación*, representa un área difusa de pigmentación disminuida dentro de una lesión pigmentada común. Las áreas blancas en un melanoma tienen una ubicación excéntrica y una forma irregular. Las áreas blancas en un *nevo* se ubican en la periferia de la lesión [29]. En la Figura 5 se muestran ejemplos de *hipopigmentación*.

Figura 5 En la fotografía de la izquierda se puede observar un *nevo* con *hipopigmentación*, mientras que en la fotografía de izquierda se observa un melanoma con *hipopigmentación* [29].



Dalal entre otros autores propuso un método para discriminar los melanomas de los *nevos* benignos detectando automáticamente las áreas blancas y las características de medición de estas áreas blancas. Para identificar las áreas blancas e *hipopigmentadas*, se determinaron los umbrales para cada plano de color basado en el análisis del histograma de color utilizando un conjunto de imágenes de entrenamiento. Se seleccionó una red neuronal como clasificador. 244 imágenes benignas y malignas con áreas blancas. Los métodos usados de forma aleatoria con un conjunto de entrenamiento seleccionado 75 lesiones y un conjunto de prueba de 169 lesiones. Como resultado se obtuvo una sensibilidad (85%) y una especificidad (85%) [29].

*Una estructura de regresión*, es una despigmentación de cicatriz blanca distribuida irregularmente dentro de la lesión [29].


*Un patrón vascular*, y más específicamente, de naturaleza atípica, presenta vasos lineales irregulares o punteados que no se combinan claramente con estructuras de regresión y que están asociados con alteraciones de la *red de pigmentos, puntos / glóbulos y / o vetas*. [29].

### 3.3 Verificación *ABCD*

La aplicación clínica de la lista de verificación *ABCD* puede mejorar la detección melanomas. Aunque los melanomas pueden carecer de una o más de estas características, su presencia, especialmente en combinación, debería levantar sospechas de malignidad. Se ha informado que la lista de verificación *ABCD* tiene una sensibilidad de 92 a 100 por ciento y una especificidad del 98 por ciento para la detección del melanoma. En las siguientes imágenes se hace referencia de lo que *ABCD* significa [30]:


*A*: Asimetría. Sugestivo de melanoma si la lesión es dividida y sus mitades no son simétricas. En la Figura 6 se observa un ejemplo de simetría y no simetría.

Figura 6 En la fotografía de la izquierda se observa un *nevo* simétrico, mientras que en la fotografía de la derecha se observa un melanoma no simétrico [30].



**B: Borde irregularidad.** Sugestivo de melanoma si el borde es irregular. En la Figura 7 se muestran ejemplos de bordes regular e irregular

Figura 7 En la fotografía izquierda se observan bordes regulares (benignos) mientras que en la fotografía derecha se observan bordes are irregular (melanoma maligno [30].



**C: Color variado.** Sugestivo de melanoma si hay más de una sombra de pigmento. En la Figura 8 se muestran ejemplos de tono/color variado y de tono/color uniforme.

Figura 8 En la fotografía de la izquierda se muestra una lesión con un tono / color uniforme (benigno), mientras que en la fotografía de la derecha se observan dos o más tonos / colores desiguales (melanoma maligno) [30].



**D: Diámetro** Sugestivo de melanoma. Si el diámetro es mayor a 6 mm.

La lista *ABCD* se puede usar como un algoritmo médico que tiene la intención de facilitar el diagnóstico de melanoma a aquellos observadores con menos experiencia en la técnica. Se basa en la valoración de cuatro criterios como se puede ver en la Tabla 2 [31]:

Tabla 2 Puntuación de la "regla *ABCD*" para asimetría, borde, color y estructuras dermatoscópicas [31].

Criterios dermatoscópicos	Puntuación	Factor de ponderación / corrección
<b>Asimetría</b>	0 a 2	X 1.3
<b>Borde</b>	0 a 8	X 0.1
<b>Color</b>	1 a 6	X 0.5
<b>Estructuras dermatoscópicas</b>	1 a 5	X 0.5

Consideraciones de puntuación [31]:

- *Asimetría*: la lesión pigmentada se divide en dos ejes perpendiculares, en tal forma de lograr la mayor cantidad de simetría posible, y se evalúa la asimetría con respecto a la forma, el color y la estructura en ambos lados de cada eje. Se otorga una puntuación de cero si no hay asimetría en ningún eje, de 1 si existe asimetría en un eje y de 2 si se presenta en ambos ejes, de tal manera que la lesión puede tener una puntuación de cero - dos.
- *Borde*: la lesión se divide en ocho segmentos y se puntúa con uno cada porción que podría presentar una terminación abrupta del borde. De tal manera que el puntaje mínimo que se puede obtener es 0 y el máximo es 8.
- *Colores*: evalúa la presencia de 6 colores (blanco, marrón claro, marrón oscuro, azul-gris, rojo y negro). En consecuencia, la puntuación máxima será de seis y la mínima 1. El color blanco solo se puntuará si es más claro que la piel adyacente; es decir, cuando pertenece a áreas blancas de regresión.
- *Estructuras dermoscópicas*: En el cuadro clínico *ABCD*, aplicable a imágenes macroscópicas aplicables, la "D" corresponde al Diámetro y se considera un síntoma de malignidad que cae desde 6 mm. Aquí, estamos describiendo el *ABCD* dermoscópico, en el cual la "D" es correspondiente a estructuras. Se consideran cinco estructuras, cada una de ellas con una puntuación de 1. En consecuencia, la puntuación máxima será de cinco y el mínimo de uno. Los patrones dermoscópicos son:
  - *Red pigmentada (reticular)*: si es típica o atípica.
  - *Áreas homogéneas y no estructuradas*: deben cubrir más del 10% de la lesión.
  - *Puntos*: deberían ser más de dos.
  - *Glóbulo*: debe ser al menos dos.
  - *Ramificaciones lineales*: deberían ser más de dos.

Posteriormente, cada valor se multiplica por cada factor de ponderación, las puntuaciones parciales se agregan, y se obtiene la puntuación dermoscópica total (*TDS Total Dermoscopic Score*). Una vez calculado el *TDS*, se determina el diagnóstico, con los siguientes rangos como se muestra en la Tabla 3 [31]:



Tabla 3 Valores de *TDS* para clasificar una lesión en benigna, sospechosa y maligna [31].

<b>TDS</b>		
<4.75	4.8–5.45	>5.45
BENIGNO	SOSPECHOSO	MALIGNO

Valores de *TDS*.

Entonces las tareas del ciclo de vida de un sistema automatizado para la detección de melanoma podrían ser [31]:

1. Adquisición de la imagen: se lleva a cabo la adquisición de la imagen dermoscópica.
2. Pre procesamiento de imagen: se lleva a cabo el pre procesamiento de la imagen. *Primero* la mejorar en la calidad de la imagen, con el objetivo de representarla tan cerca como sea posible la lesión original. *En segundo lugar*, y está aquí donde realmente comienza el proceso automatizado de una herramienta de software, la detección y tratamiento del "ruido", como: cabello, burbujas, flashes, sombras, marcas de tinta en la piel, electrónica marcas (generalmente identificadores digitales o información de copyright), marcos y dispositivos negros y gobernantes para medir.
3. Segmentación de la lesión cutánea: se lleva a cabo la segmentación de la lesión cutánea. Por costumbre, se realiza de forma automatizada. No obstante, existen sistemas semi automatizados los que se permite al experto intervenir en esta etapa, introduciendo información para la mejora de la segmentación.
4. Detección y caracterización de indicadores: la detección automatizada y caracterización de los indicadores elegidos para llevar a cabo el diagnóstico.
5. Diagnóstico: Sobre la base del algoritmo médico, el cálculo cuantitativo del grado de malignidad se realiza para determinar el diagnóstico de acuerdo con los rangos de los valores preestablecidos.


## 2.5 El cáncer de piel y la inteligencia artificial

Existen cuatro tipos de cáncer de piel: *queratosis actínicas (AK)*, *carcinoma de células basales (BCC)*, *carcinoma de células escamosas (SCC)* y *melanoma*. [5]. La investigación clínica ha demostrado que el cáncer de piel es un importante problema de salud pública. Esta entre los cánceres más comunes en Estados Unidos de América, es responsable de 10,000

muerdes anuales tan solo ese país [6]. Según los datos estadísticos de la Organización Mundial de la Salud (OMS), cada año se producen entre 2 y 3 millones de cánceres de piel no melanoma y 132,000 cánceres de piel tipo melanoma [7]. Los profesionales de la salud especialmente capacitados para detectar el cáncer de piel pueden utilizar imágenes dermatoscópicas para evaluar la posibilidad de melanoma desde el principio y pueden obtener una precisión diagnóstica tan alta como ~ 80% [8].


Para el análisis computarizado de las imágenes se cuenta con algunos conjuntos de datos disponible en los que se encuentran el archivo dermatoscópico, como por ejemplo el *ISIC (The International Skin Imaging Collaboration)* [6] [9]. En estas imágenes dermatoscópicas se encuentran factores, que podrían tener un efecto negativo en la precisión de la clasificación. En la Figura 9 se puede observar algunos de estos factores [6], [8].

Figura 9 Factores comunes en imágenes dermatoscópicas. Primera fila: una imagen normal, una esquina oscura y bello de la piel, de izquierda a derecha, respectivamente. Segunda fila: artefacto de colores, marcador de regla y marcador de tinta [6].




Estos factores pueden llevar a una inexactitud de la clasificación y el modelo dará un resultado de predicción incorrecto. Para evitar eso, las imágenes se exponen a varias técnicas de procesamiento de imágenes. Por ejemplo, para eliminar los ruidos de fondo, como el bello y las burbujas de aire y otros ruidos en la imagen de la piel como se muestra en la Figura 10 [8].

Figura 10 A la izquierda se muestra una imagen con bello, a la derecha la imagen ya procesada ya sin bello [8].



Se puede usar *K-means* (*K-medias*,  $K^*$ ) y algunos filtros como *Gabor* para segmentar la imagen. Para segmentar una imagen en diferentes regiones de texturas similares basadas en una especificada. En la Figura 11 se observa un ejemplo:

Figura 11 A la izquierda se observa una imagen no segmentada a la derecha una imagen segmentada [8].



La extracción de características es una de las fases más importantes del procesamiento de imágenes. *Las redes neuronales de convolución profunda (CNN o DCNN Deep Convolutional Neural Network)*, es un tipo específico de algoritmo de aprendizaje profundo, superan el problema en los algoritmos de aprendizaje automático tradicionales que requerían la extracción manual de características antes del proceso de clasificación. Las *CNN* no solo realizan la clasificación, sino que también pueden aprender a extraer características directamente de imágenes en bruto. Las *CNN* proporciona la flexibilidad de extraer características intrínsecas y discriminatorias de imágenes, esas son las más adecuadas para la clasificación [8].

Además de las bases de datos de imágenes Es posible uso de *CNN* pre-entrenadas establecidas, que se capacitaron en más de 1.4 millones de imágenes naturales con diversas

condiciones fotográficas. Estas redes se pueden utilizar como extractores de características optimizados para imágenes dermatoscópicas [6].

## 2.6 Trabajos sobre el cáncer de piel y técnicas de clasificación

### 2.6.1 Mahbod

Mahbod et al [6] tomaron imágenes disponibles del *ISIC* en 2017. Aplicaron tres pasos de pre procesamiento en las imágenes. Primero, normalizaron las imágenes restando el valor *RGB* medio del conjunto de datos, ya que las redes pre-entrenadas fueron optimizadas para esas imágenes. A continuación, las imágenes se redimensionaron al tamaño apropiado utilizando interpolación bicúbica para alimentar a las redes (227 X 227 y 224 X 224).

Finalmente, hicieron un incremento imágenes para tener un conjunto de entrenamiento más grande. Para el aumento de datos, rotaron las imágenes a 0, 90, 180 y 270 grados y luego aplicaron inclinación horizontal a cada imagen y del conjunto de datos artificiales derivados, utilizaron el 80% de las imágenes al azar para entrenar a los clasificadores.

Utilizaron dos redes pre-entrenadas. La arquitectura *AlexNet* pre-entrenada y la arquitectura *VGG-16* como extractor de características. Usaron las características de extracción de diferentes capas de modelos pre-entrenados para ver cómo podrían afectar los resultados de la clasificación. Estas características, junto con las etiquetas correspondientes (tipo de piel) las usaron para entrenar a *los clasificadores de máquinas de vectores de soporte no lineales (SVM) de clases múltiples*.

Capacitaron a diferentes clasificadores para cada red y luego promediaron la puntuación de la clase para obtener el resultado de la clasificación final. Para evaluar los resultados de la clasificación, mapearon los puntajes de *SVM* a las probabilidades usando regresión logística.

Dado que los clasificadores fueron entrenados para un problema de clasificación múltiple (tres clases que incluyen *melanoma*, *queratosis seborreica* y *clases de nevos benignos*), combinaron las puntuaciones para obtener los resultados de dos problemas de clasificación binaria, que fueron la clasificación de melanoma y la clasificación de la enfermedad queratosis seborreica.

El rendimiento del clasificador, en términos de precisión (*ACC*) y área bajo la curva de características operativas del receptor (*AUC*) se midieron para 150 imágenes de prueba. Los

resultados resumidos de la clasificación en las imágenes de prueba se muestran en la Tabla 4.

Para calcular la precisión, se usó una probabilidad del 50% como umbral. Todos los experimentos se realizaron en una computadora portátil con *NVIDIA GTX 840M 2GB, 6 GB* de memoria instalada y *CPU Intel Core i7-4500U a 1.8 GHz*. La implementación principal del algoritmo se realizó con *MATLAB* (versión 2016b) y el marco *MatConvNet* para *CNN*. El tiempo de ejecución del algoritmo implementado para entrenar *SVM* y extraer funciones fue de alrededor de 70 minutos y para las pruebas en todas las imágenes de prueba fue de alrededor de cinco minutos [6].

Tabla 4 Resultados resumidos. M significa melanoma y SK significa queratosis seborreica [6].

Network	Capa de características	M- ACC	SK- ACC	M- AUC	SK- AUC	Promedio de AUC
<b>AlexNet</b>	FC8	83.3	88.0	78.4	90.3	84.3
<b>ALexNet</b>	All FC	84	89.3	82.28	94.9	88.9
<b>VGG-16</b>	FC8	82.7	79.3	78.8	81	79.9
<b>VGG-16</b>	All FC	85.3	88.0	81.9	92.8	87.3
<b>Fusion</b>	All FC	84.7	84.7	84.8	93.6	89.2

### 2.6.2 Hao

Hao [9] usando las imágenes de *ISIC*, trató de resolver dos problemas principales: 1) El problema de reconocimiento de lesiones de la piel. El reconocimiento de las lesiones de la piel para que las cámaras y las computadoras detecten y se acerquen automáticamente las regiones de la lesión. Intentó muchas estrategias y finalmente tomó la red neuronal basada en *U-Net6* y logró una buena detección y precisión de reconocimiento. 2) El juicio del melanoma.

Utilizó la estrategia de transferencia de aprendizaje (*TL Transfer Learning*) basada en la red neuronal *Inceptions\_v3* bien entrenada de *Google*. Esta nueva red diseñada también ayuda a lograr una precisión de predicción de melanoma muy alta. Tomó 2000 imágenes dermatoscópicas incluye 374 imágenes de melanoma, 1372 imágenes de *nevus* y 254 imágenes de queratosis seborreica.

Los datos de validación incluyen 150 imágenes sin etiquetar y los datos de prueba finales contienen 600 imágenes sin etiquetar y algunos datos básicos del paciente, incluidos la edad y el género. Pero en su entrenamiento y pruebas de red neuronal, abandonó la utilidad de la información del paciente. Se ha demostrado que el melanoma depende de la edad y el género, sin embargo, estos dos parámetros los eliminó.

Todas las imágenes las redimensionó a 150X150. Tres canales de las imágenes dermatoscópicas (Rojo, Verde, Azul) se utilizan en la red neuronal. Normalizó las imágenes de entrada restando la intensidad de píxel media y dividiendo la desviación estándar. Este tratamiento hace que el valor medio de la imagen sea cero y la desviación estándar sea 1. Los datos de entrada fueron 2000 imágenes tratadas.

Agregaron imágenes de lesiones cutáneas recortadas de los conjuntos de datos, porque las imágenes de alta definición son muy importantes para la claridad de los dermatólogos. Para la validación y prueba, las imágenes recortadas se obtienen de los resultados de una red de segmentación.

La Red de segmentación: la red neuronal de segmentación de lesión de piel (*skin\_segnn*) es similar a la arquitectura *U-Net*. Es impulsada por el paquete de aprendizaje profundo *Tensorflow, Theano y Keras*. La imagen de entrada son las imágenes originales y la salida son las máscaras de segmentación.

La Red de Reconocimiento: la red neuronal de reconocimiento de melanoma (*skin\_recnn*) se basa en la estructura de la red de *Google Inceptions V3* (Figura 2B). La capa de salida de *Inceptions V3* se reemplaza por capas de conexión completa (1024 nodos). El peso inicial de esta red es el peso bien entrenado de los conjuntos de datos de *ImageNet*. Hay dos redes neuronales *Inceptions V3* en su diseño. Uno está a cargo de las imágenes dermatoscópicas de tamaño completo, el otro está a cargo de las imágenes dermatoscópicas recortadas de *skin\_segnn*, que solo mantienen la región de la lesión principal. Luego, ambos 1024 nodos se fusionan y la capa de salida con 3 nodos se vincula a continuación.

Estos tres nodos representan las tres clases que incluyen melanoma, *nevo* y *queratosis seborreica*. Primero entrenaron la red congelando todas las capas de *Inception V3*. Luego, los dos bloques finales de las capas *Inception V3* fueron entrenados. Sin embargo, este autor

hasta ahora no publica sus resultados, pero es interesantes observar las redes pre entrenadas que utilizó.

### 2.6.3 Yang

Yang et al [10], se utilizaron *DCNN (Deep CNN)* multitarea. Para el análisis lesiones cutáneas. A diferencia de la *DCNN* convencional, en la arquitectura de aprendizaje multitarea, la imagen dermatoscópica de entrada puede asociarse con múltiples etiquetas que describen diferentes características de la lesión. El modelo *DCNN* multitarea que implementó se basa en las arquitecturas de diseño de *GoogleNet*.

Los conjuntos de datos dermatoscópicos de formación y evaluación se tomaron de *ISIC 2017*. 2000 muestras en el conjunto de datos de capacitación y 150 muestras en el conjunto de datos de evaluación. Los resultados de la clasificación son evaluados por el área bajo la curva de características operativas del receptor (*AUC*). El *AUC* es una medida de qué tan bien un parámetro puede distinguir entre dos grupos de diagnóstico (enfermo / normal). En la Tabla 5 compararon el rendimiento entre *DCNN* multitarea y *GoogleNet*.

Tabla 5 Comparación el rendimiento entre *DCNN* multitarea y *GoogleNet* [10].

Método	El modelo propuesto	GoogleNet
AUC (Área bajo la curva)	0.926	0.903

### 2.6.4 Shoieb

Shoieb et al [7] tomaron una *CNN* pre-entrenada en su última fase para clasificar la lesión infectada de la piel según las características de la *CNN* para entrenar un clasificador *SVM* multiclase.

Hay varias redes pre-entrenadas que han ganado popularidad. La mayoría de estos han sido entrenados en el conjunto de datos de *ImageNet*, que tiene 1000 categorías de objetos y 1.2 millones de imágenes de entrenamiento. *AlexNet* es uno de esos modelos y se puede descargar desde *MatConvNet*; es una *CNN* que entrenó utilizando dos *GPU* diferentes.

Recopilaron 337 imágenes de lesiones de la piel con hechos reales, que se obtuvieron con cámaras estándar de uso en condiciones ambientales variables y sin restricciones. Estas imágenes fueron extraídas de dos bases de datos diferentes.

El primer conjunto de datos de las bases de datos en línea disponibles públicamente *Dermatology Information System* . El conjunto de datos comprende 69 imágenes, 43 de ellas representan melanoma y 26 para cáncer de piel no melanoma.

El segundo conjunto de datos es de *DermQuest*. El conjunto de datos comprende 134 imágenes, 76 de ellas representan melanoma y 58 para cáncer de piel no melanoma.

El tercer conjunto de datos fue para la validación del sistema propuesto para enfermedades de múltiples clases. Este conjunto de datos se obtuvo del sitio web *DermNet Skin Disease Atlas* que tiene 27 clases de enfermedades.

Se han seleccionado cuatro clases de enfermedades de la piel para la validación del sistema; estas clases son: *Melanoma, Carcinoma de células basales, Eczema e Impétigo*.

El conjunto de datos comprende 134 imágenes, 72 de ellas representan melanoma, 64 para carcinoma de células basales, 74 eccemas y 31 para la enfermedad de la piel por *impétigo*.

Se han realizado experimentos para validar la eficiencia del modelo propuesto. Los experimentos se llevaron a cabo en un procesador *Core i5 a 2,3 GHz con 8 GB de RAM* utilizando *MATLAB 9.0*. Los resultados que obtuvieron se observan en las siguientes Tablas 6, 7 y 8:

Tabla 6 Resultados de la clasificación de lesiones de melanoma y no melanoma de los datos obtenidos de *Dermatology Information System* [7].

Enfermedad de la piel	Exactitud (Accuracy)	Especificidad	Sensibilidad
<b>Melanoma</b>	93.75%	100%	87.5
<b>No melanoma</b>	93.75%	87.5%	100%

Tabla 7 Resultados de la clasificación de lesiones de melanoma y no melanoma de los datos obtenidos de *DermQuest*. [7].

Enfermedad de la piel	Exactitud (Accuracy)	Especificidad	Sensibilidad
<b>Melanoma</b>	94.12%	94.12%	94.12%
<b>No melanoma</b>	94.12%	94.12%	94.12%



Tabla 8 Resultados de la clasificación de melanoma, carcinoma de células basales, eczema e impétigo de los datos obtenidos de *DermNet Skin Disease*. [7].

Enfermedad de la piel	Exactitud (Accuracy)	Especificidad	Sensibilidad
<b>Melanoma</b>	98.04%	100%	88.89%
<b>Carcinoma de células basales</b>	96.15%	96%	88.89%
<b>Eczema</b>	94.12%	100%	77.78%
<b>Impétigo</b>	91.12%	88.4	100%

### 2.6.5 Codella

Codella et al [11] experimentaron con el método de validación cruzada dos veces. Con 334 imágenes de melanoma y 144 imágenes de *nevus atípicos*, así como 2146 lesiones claramente benignas (2624 en total) tomadas de *ISIC*.

Realizaron dos variantes de la tarea: una tarea que discrimina el melanoma tanto de lesiones atípicas como benignas (tarea más fácil), y una tarea que discrimina el melanoma solo de las lesiones atípicas (tarea más difícil).

Tomaron dos caminos paralelos: 1) La transferencia de las características de la red neuronal convolucional aprendidas del dominio de las fotografías naturales, y 2) el aprendizaje de las características sin supervisión, utilizando codificación dispersa, dentro del dominio de las imágenes de dermatoscopia.

Los clasificadores se entrenaron para posteriormente utilizar *SVM* no lineales, y los modelos se combinan en la fusión tardía (puntaje promedio). El trabajo lo realizaron con una *CNN* de *Caffe* desarrollada en *Berkeley*. Tomaron un modelo pre-entrenado de *Image Large Scale Visual Recognition Challenge (ILSVRC)* de 2012. Este modelo pre-entrenado incluye cinco capas convolucionales, dos capas completamente conectadas y una capa final para el detector de 1000 dimensiones.

En este trabajo, el concepto de capa detectora de este modelo (1000 dimensiones, denominado “*FC8*”), así como la primera capa totalmente conectada (4096 dimensiones, denominada “*FC6*”), se utilizan como descriptores visuales para las imágenes dermatoscópicas.

Para la codificación dispersa que es una clase de métodos no supervisados que busca aprender de un diccionario de códigos dispersos de los cuales un conjunto de datos determinado se

puede reconstruir un conjunto de datos determinado. Se construyen dos diccionarios en color (*RGB*) y espacios de color en escala de grises. Las imágenes se redimensionan a dimensiones de 128x128 píxeles antes de la extracción de 8x8 parches, para aprender diccionarios de 1024 elementos.

Para entrenar clasificadores usaron una *SVM* no lineal que utiliza un núcleo de intersección de histograma y usaron función sigmoide; además normalizaron las características. Las puntuaciones *SVM* se asignaron a las probabilidades mediante regresión logística en los datos de entrenamiento. Utilizaron una probabilidad del 50% como umbral de clasificación binaria. La fusión se realiza mediante un promedio de puntuación *SVM* no ponderada (fusión tardía). En las Tablas 9 y 10 se observan los resultados obtenidos.

Tabla 9 Resultados de rendimiento: melanoma vs atípico y benigno [11].

	Conjunto codificado a mano	Caffe	Codificación	Fusiones	Gris	RGB	Fusión	Profundo	Todo
		CNN	dispersa						
		4K FC6	1K FC8	Fusión					
<b>Exactitud (Accuracy)</b>	0.912	0.919	0.853	0.910	0.825	0.903	0.907	0.923	0.931
<b>Especificidad</b>	0.930	0.903	0.805	0.893	0.823	0.885	0.905	0.925	0.949
<b>Sensibilidad</b>	0.910	0.921	0.860	0.860	0.825	0.906	0.907	0.923	0.928

Tabla 10 Resultados de rendimiento: Melanoma vs atípico [11].

	Conjunto codificado a mano	Caffe	Codificación	Fusiones	Gris	RGB	Fusión	Profundo	Todo
		CNN	dispersa						
		4K FC6	1K FC8	Fusión					
<b>Exactitud (Accuracy)</b>	0.715	0.723	0.654	0.725	0.825	0.681	0.695	0.728	0.739
<b>Especificidad</b>	0.727	0.724	0.664	0.725	0.823	0.643	0.691	0.728	0.738
<b>Sensibilidad</b>	0.689	0.722	0.632	0.7232	0.825	0.670	0.706	0.729	0.743

### 2.6.6 Dorj

Dorj et al [5] hicieron una clasificación de los cánceres de piel utilizando una red neuronal convolucional profunda. El hardware utilizado incluye: *Intel Core i7 con 2.20GHz, 8.00GB*

DDR3 de doble canal a 665 MHz , Tarjeta gráfica NVIDIA de 2047 MB GeForce GT 54 M. Usaron *Matlab R2016b* para analizar imágenes en su investigación. EL algoritmo para obtener la metodología general que utilizaron es el siguiente:

Adquisición datos de imagen:

- Recoger datos de imagen
- Cortar las imágenes
- Preparar entrenamiento y probar conjuntos de imágenes.

Clasificación en grupos que utilizan funciones de red neuronal convolucional:

- Extraer funciones de entrenamiento utilizando una red neuronal convolucional.
- Entrene y pruebe un clasificador *ECOC-SVM* utilizando las funciones de red neuronal convolucional.

El conjunto de datos en este estudio se originó en sitios de Internet relacionados. En este estudio, utilizaron imágenes *RGB* de cáncer de piel con 500–1000 píxeles, *jpg* y *tiff*. Con un total de 3753 imágenes, que se recopilan de Internet (google.com y naver.com, baidu.com y bing.com).

Algunas imágenes recopiladas tienen ruidos, como otros órganos o herramientas. Esas imágenes se recortaron para reducir los ruidos para un mejor resultado. Las imágenes se agrupan por cuatro tipos de cáncer de piel (*queratosis actínica, carcinoma de células basales, carcinoma de células escamosas y melanoma*) y se guardan en diferentes carpetas para el entrenamiento y el proceso de prueba.

Las imágenes adquiridas se procesaron mediante una red neuronal convolucional profunda, y las características de la red neuronal convolucional obtenida se clasifican en cuatro grupos: *queratosis actínica, carcinoma de células basales, carcinoma de células escamosas y melanoma*.

Usaron para la clasificación *ECOC SVM* y utilizaron un modelo de red neuronal convolucional pre-entrenada *AlexNet*. En la Tabla 11 se observan sus resultados.

Tabla 11 Resultado de la implementación de la clasificación de cáncer de piel [5].

Nombre del cáncer	Exactitud (Accuracy)	Especificidad	Sensibilidad
<b>Queratosis Actínicas</b>	92.3	91.67	98.9
<b>Carcinoma basocelular</b>	91.8	86.73	97.7
<b>Carcinoma de células escamosas</b>	95.1	94.17	96.9
<b>Melanoma</b>	94.2	90.74	97.83

### 2.6.7 Liao

Liao [12] hizo una clasificación de enfermedades de la piel. Su conjunto de datos de enfermedades de la piel a partir de dos fuentes diferentes: *Dermnet* y *OLE*. *Dermnet*.

*OLE*. *Dermnet* es una de las fuentes de dermatología fotográfica más grande que está disponible públicamente. Tiene más de 23,000 imágenes de enfermedades de la piel en una amplia variedad de afecciones de la piel.

*Dermnet* organiza biológicamente las enfermedades de la piel en una taxonomía de dos niveles. El nivel inferior contiene más de 600 enfermedades de la piel. El nivel superior contiene 23 clases de enfermedades de la piel. Cada una de las clases de enfermedades de la piel de nivel superior contiene una subcolección de las enfermedades de la piel de nivel inferior.

Adaptaron la taxonomía de enfermedades de la piel de *Dermnet* para su sistema de clasificación y utilizaron las 23 clases de enfermedades de la piel de nivel superior para etiquetar todas las imágenes de enfermedades de la piel. El conjunto de datos *OLE* contiene más de 1300 imágenes de enfermedades de la piel del Departamento de Salud del Estado de Nueva York. Contiene 19 enfermedades de la piel, cada una de las cuales puede asignarse a una de las enfermedades de la piel del nivel inferior de la taxonomía *Dermnet*. Por lo tanto, etiquetaron aún más estas 19 enfermedades de la piel con sus contrapartes de alto nivel en la taxonomía *Dermnet*.

En varios trabajos se toma una red pre-entrenada, esto funciona porque la salida de las primeras capas de una red bien entrenada generalmente contiene algunas características genéricas. Esas características genéricas, como los bordes y las manchas, pueden ser muy

útiles en muchas tareas. Para un nuevo conjunto de datos, esas características se pueden aplicar directamente.

En este, transfirieron el aprendizaje de los modelos pre-entrenados de *ImageNet* con *Caffe*, un marco de aprendizaje profundo que apoya la capacitación profunda y expresiva de *CNN*. Elegieron *VGG16*, *VGG19* y *GoogleNet* como sus modelos pre-entrenados. En las Tablas 12 y 13 se muestran los resultados que obtuvieron.

Tabla 12 *Accuracy* de las *CNNs* usando diferentes modelos pre-entrenados de *ImageNet*, todas las *CNN* se entrenaron utilizando las imágenes *Dermnet* solamente [12].

Modelo CNN	Accuracy
<b>VGG16</b>	91%
<b>VGG19</b>	90.9%
<b>GoogleNet</b>	90.7%

Tabla 13 Utilizando sólo el modelo *VGG19*. Se prueban en las imágenes *OLE*, para *VGG19* Mejorado, se usa el conjunto de datos refinado [12].

Modelo CNN	Accuracy
<b>VGG19</b>	61.7%
<b>VGG19 Mejorado</b>	69.5%

## 2.6.8 Georgakopoulos

Georgakopoulos et al [13] clasificaron imágenes dermatoscópicas con dos clases como "malignos" o "no malignos". Trataron de usar una entrada mejorada a la *CNN* usando los filtros *Gaussiano*, *Laplaciano de Gaussiano (LoG)*, *matriz Hessiana* y *Gabor*. Ellos investigaron el valor de aumentar las entradas de *CNN* con filtros usados en visión de computadora.

La respuesta de cada imagen disponible con estos filtros se calcula y se usa como entrada adicional a la *CNN*. Además usaron *TL* utilizando dos arquitecturas de red pre-entrenada. *TL*, es muy útil en casos de conjuntos de datos que no son adecuados para capacitar a una red *CNN* completa, debido al pequeño tamaño de los datos de entrada.

Las arquitecturas de dos *CNN* pre-entrenadas fueron:

La primera arquitectura CNN (“*arch1*”), conocida como *AlexNet*, consta de cinco capas convolucionales, cada una con una función de activación *ReLU* y seguida de una capa de agrupación máxima y dos capas completamente conectadas. *AlexNet (arch1)* es una arquitectura CNN ampliamente utilizada que se entrenó previamente en el conjunto de datos *ImageNet*, que contiene 1000 objetos diferentes de imágenes del mundo real. Esta red pre-entrenada produce una gran cantidad de filtros genéricos en las primeras capas, mientras que las últimas capas tienden a estar más ajustadas al problema específico en cuestión.

La segunda arquitectura CNN (“*arch2*”) consta de cuatro capas convolucionales, seguidas de una de agrupación máxima, así como una quinta, seguidas de dos capas totalmente conectadas; donde se utiliza para identificar anomalías en las imágenes endoscópicas.

Pero dado que las CNN pre-entrenadas en imágenes de dermatoscopia no están disponibles públicamente, ellos realizaron la TL de la siguiente manera. Los pesos de conexión de la arquitectura de *AlexNet* (“*arch1*”) se transfieren a las arquitecturas de red propuestas, mientras que los pesos de conexión de la entrada basada en filtros en la primera capa de la red se inicializan aleatoriamente.

Expandieron los datos con técnicas típicas de expansión de datos específicamente, esto lo hicieron con los siguientes dos pasos:

- Paso 1: el conjunto de imágenes de piel malignas se amplía aplicando rotaciones de imagen en múltiplos de 90 grados, así como transformaciones de espejo en cada imagen girada.
- Paso 2: Para *arch1*, todas las imágenes se redimensionan a 256 x 256. Un procedimiento de preprocesamiento extrae muestras de imagen de 224 X 224 en ubicaciones aleatorias de la imagen redimensionada, que se utilizan como entrada a la CNN. De manera similar, para CNN *arch2*, las imágenes se redimensionan a 352 x352. La etapa de preprocesamiento extrae muestras de imagen de 320 x 320 en ubicaciones aleatorias de la imagen redimensionada, que se utilizan como entrada a la CNN.

El conjunto de datos expandido se usa solo para entrenamiento, y las imágenes producidas no necesitaron ser almacenadas. Los resultados que obtuvieron se observan en la Tabla 14:

Tabla 14 Resultados de clasificación logrados para el problema de clasificación de imágenes de dos clases con datos de entrada aumentados basados en filtro [13].

	Accuracy	Especificidad	Sensibilidad
<b>arch1</b>	92.3%	100%	0
<b>arch2</b>	92.3%	100%	0
<b>TL-arch1</b>	93.9%	94.3%	88.1%
<b>TL-arch2</b>	88.6%	90%	69.5%

Cabe mencionar que ellos también se dieron a otra tarea importante en el análisis de imágenes de dermatoscopia para el cáncer de piel tipo melanoma, la detección de estructuras específicas:

- *Rayas*: estructuras lineales de color marrón-negro de espesor variable, no claramente combinadas con líneas de red de pigmento, principalmente en la periferia de la lesión.
- *Red de pigmentos*: oscuras, estructuras lineales altamente interconectadas.
- *Quistes de Milia*: estructuras circulares que aparecen como puntos / glóbulos oscuros.
- *Red negativa*: aparece como negativa de la red pigmentada, y se cree que es una estructura específica del melanoma.

Utilizaron un procedimiento similar al de clasificaron imágenes dermatoscópicas como "malignos" o "no malignos". Pero sin la expansión de datos y tampoco usaron *TL*. Debido a que nuestro objeto de estudio es la clasificación binaria de "malignos" o "no malignos", no se mencionaran tantos detalles de este proceso. Los resultados que obtuvieron se observan en la Tabla 15 y 16

Tabla 15 Resultados de clasificación en el conjunto de datos de validación con datos de entrada RGB [13].

	Clases			
	Red de pigmentos	Red negativa	Rayas	Quistes de Milia
<b>Accuracy</b>	75.5%	76.2%	83.2%	78.9%
<b>Especificidad</b>	77.8%	77.6%	83.4%	40.4%
<b>Sensibilidad</b>	44.7%	42.5%	57.2%	79.1%

Tabla 16 Resultados de clasificación en el conjunto de datos de validación con datos de entrada aumentados basados en filtros [13].

Clases				
	Red de pigmentos	Red negativa	Rayas	Quistes de Milia
<b>Accuracy</b>	72.2%	88.7%	97.4%	92.2%
<b>Especificidad</b>	54.6%	90.1%	97.7%	76.6%
<b>Sensibilidad</b>	74.6%	45.3%	57.2%	92.1%

### 2.6.9 Grzesiak-Kopec

Grzesiak-Kopec et al [14] presentaron tres métodos de aprendizaje automático usando diferentes clasificadores, el clasificador *Naive Bayes*, el clasificador aleatorio de bosques aleatorios y clasificador basado en instancias  $K^*$ , junto con dos algoritmos de meta-aprendizaje: la agregación *Bo otstrap (Bagging)* y *Vote Ensemble Classifier*.

En este trabajo, la descripción de las muestras proporcionada en *The Interactive Atlas of Dermoscopy*. Tomaron 1010 casos clínicos 275 de melanoma y 735 de lesiones benignas. No se realizaron ningún procesamiento de imagen para extraer nuevas características.

Las muestras de lesiones cutáneas se caracterizan por 14 propiedades es este estudio: edad, sexo, ubicación, diámetro, elevación, característica global, red pigmentaria, estrías, pigmentación, estructuras de regresión, glóbulos, velo azul blanquecino, *hipopigmentación* y estructuras vasculares. Sus mejores resultados para cada clasificador se lograron después de eliminar el atributo de sexo de las muestras. Todos los atributos disponibles, excepto los de edad y ubicación, se tomaron como variables categóricas de un número fijo de valores posibles.

Los pacientes se dividieron en 6 grupos de edad: bebé de 0 a 10 años, adolescente de 11 a 19 años, joven de 20 a 30 años, adulto de 31 a 50 años, de 51 a 70 años y muy mayor de 71 a 90 años. El valor del diámetro varía de 2 a 40 mm se dividió en cinco secciones de los posibles valores, eso les dio mejores resultados de rendimiento: {2 mm, ..., 3.5 mm}, {4 mm, ..., 9 mm}, {10 mm, ..., 18 mm}, {19 mm, ..., 30 mm}, {32 mm, ..., 40 mm}.

Obtuvieron datos de entrada principalmente categóricos, así que los clasificadores usados aceptaron este tipo de datos de entrada sin ningún pre procesamiento y codificación adicionales.



Usaron como medida el área bajo la curva característica de operación del receptor (*Area under the Curve –AUC-*) Cuanto más cerca de *AUC* esté a 1, mejor será el rendimiento de diagnóstico general de la prueba. Los resultados se pueden observar en las Tablas 17, 18 y 19.

Tabla 17 Resultados para el clasificador *Naive Bayes*, *el bosque aleatorio* y *K \** [14].

	Naive Bayes		Bosques aleatorios		K *	
Clasificado como	SI	NO	SI	NO	SI	NO
Real si	211	64	193	82	200	75
Real no	80	655	50	685	56	679
Sensibilidad	0.725		0.794		0.792	
Especificidad	0.911		0.893		0.904	
	AUC = 0.921		AUC = 0.913		AUC = 0.914	

Tabla 18 Resultados del empaquetamiento (*BAGGIN*) aplicado a: el clasificador *Naive Bayes*, *el Bosque aleatorio* y el clasificador basado en instancias *K \** [14].

	Naive Bayes		Bosques aleatorios		K *	
Clasificado como	SI	NO	SI	NO	SI	NO
Real si	212	63	194	81	199	76
Real no	78	657	31	701	54	681
Sensibilidad	0.731		0.851		0.787	
Especificidad	0.913		0.896		0.9	
	AUC = 0.922		AUC = 0.937		AUC = 0.923	

Tabla 19 Los resultados del voto se aplicaron a: el clasificador *Naive Bayes*, *el Bosque aleatorio* y el clasificador basado en instancias *K \** [14].

	Promedio de probabilidades		Probabilidad máxima	
Clasificado como	SI	NO	SI	NO
Real si	210	65	211	64
Real no	52	683	60	675
Sensibilidad	0.802		0.779	
Especificidad	0.913		0.913	
	AUC = 0.932		AUC = 0.93	

## 2.6.10 Majtner

Majtner et al [15] utilizaron el conjunto de datos *ISIC*. Para la parte de entrenamiento contaron con 900 imágenes (727 imágenes de lesiones benignas y 173 imágenes de lesiones de melanoma), y para la parte prueba contaron con 379 imágenes (304 imágenes de lesiones

benignas y 75 imágenes de lesiones de melanoma). La división de muestras de entrenamiento y de prueba se realizó de forma aleatoria.

Usaron un conjunto de características extraído de los modelos de aprendizaje profundo previamente capacitados en *ImageNet*. Su método de detección de melanoma basado en la combinación del análisis discriminante lineal (*LDA*) y las características extraídas del enfoque de aprendizaje profundo. La reducción de características que usaron, condujo no solo a una reducción significativa de las funciones empleadas, sino también al aumento del rendimiento de todos los clasificadores probados en casi todas las características medidas.

En el paso de pre procesamiento de imágenes usado, primero convirtieron la imagen de color *RGB* de entrada a una imagen en escala de grises. Para este propósito, separaron tres canales de color y derivaron su valor de entropía  $E$ , que se define como:

$$E(I) = -\sum(p * \log_2 p) \quad \text{-----}1)$$

Donde  $I$  representa el canal de color de entrada y  $p$  contiene las entradas de histograma para cada valor de intensidad en él.

Para las imágenes de lesiones de la piel, el canal de color azul se identifica con mayor frecuencia como el de mayor entropía, que se correlaciona con la longitud de onda corta de la luz azul. Decidieron utilizar este tipo de conversión ya que la imagen en escala de grises resultado una captura mejor la distribución espacial de diferentes valores de intensidad, comparada con la conversión tradicional utilizando la suma ponderada de todos los canales de color.

Después de la conversión a escala de grises, utilizaron la información de la máscara binaria, que se proporcionó con el conjunto de datos, para extraer el cuadro delimitador de la lesión de piel. El siguiente paso es reducir el muestreo de la imagen desenmascarada a la resolución requerida por *AlexNet* para su primera capa convolucional ( $227 \times 227$  píxeles) mediante interpolación bicúbica.

Para extraer el conjunto de características potenciales para la detección de melanoma, emplearon un marco de aprendizaje profundo. Utilizaron la configuración y el modelo pre-entrenado de *AlexNet*. Los autores de *AlexNet* introdujeron este modelo para la clasificación de imágenes y ganaron un *Desafío de Reconocimiento Visual a Gran Escala 2012* de

*ImageNet* con una ventaja significativa sobre los demás participantes. A pesar del hecho de que *AlexNet* se creó para imágenes del mundo real, muchos investigadores también utilizaron con éxito las características derivadas de esta configuración para el reconocimiento del melanoma.

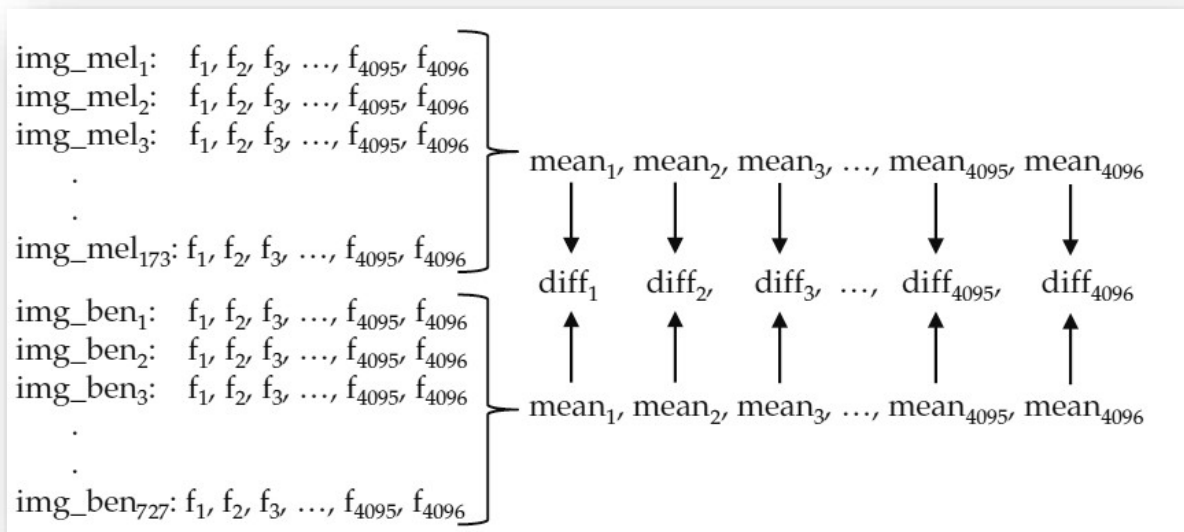
La versión original de *AlexNet* contiene cinco capas convolucionales (*CONV*) y tres capas completamente conectadas (*FC*). Cada una de estas capas es seguida por una capa de activación no lineal puntual llamada unidades lineales rectificadas (*RELU*). También hay una capa de normalización de respuesta local (*LRN*), que sigue las dos primeras capas convolucionales. *AlexNet* tiene tres capas de agrupación máxima (*MAX*), dos después de las capas *LRN* y la tercera después de la quinta capa convolucional.

La estructura central de *AlexNet* localiza entre la segunda y la tercera capas de agrupación máxima, que contiene tres capas convolucionales, cada una con  $3 \times 3$  núcleos de convolución.

En sus experimentos, utilizaron *MatConvNet*, que es una caja de herramientas de *MATLAB* que implementa redes neuronales convolucionales para aplicaciones de visión artificial. Las imágenes pre procesadas se utilizan como entradas, y se emplea *AlexNet* para extraer las características correspondientes a la activación de la segunda capa totalmente conectada. Esta capa tiene 4096 elementos, que en su estudio se utilizaron como características potenciales para la tarea de detección de melanoma. El uso de la activación de la capa totalmente conectada como el vector de características se empleó previamente en la visión artificial para la clasificación de vehículos, pero también para el reconocimiento melanoma.

Para la reducción de conjunto de características utilizando *LDA*, se cuenta entonces con 4096 funciones para cada imagen de entrada de la parte de entrenamiento del conjunto de datos. La parte de entrenamiento del conjunto de datos consta de 727 imágenes de lesiones benignas y 173 imágenes de lesiones de melanoma. Utilizaron el conjunto de datos de entrenamiento en dos subconjuntos basados en él. Posteriormente, calcularon el valor medio de cada componente de la característica dentro de ambos subconjuntos. Como resultado, terminaron con 4096 valores medios para las características de las lesiones benignas y el mismo número de valores medios para las características de las lesiones de melanoma. En el siguiente paso, derivaron las diferencias absolutas de los valores medios correspondientes de ambos subconjuntos, como se muestra en la Figura 12, y los clasificaron en orden ascendente.

Figura 12 Ilustración de *LDA* utilizada para la identificación de las características más discriminatorias para el conjunto de datos de entrenamiento. Las imágenes de una lesión de melanoma se indican como *img\_mel* y las imágenes de una lesión benigna como *img\_b*. Los valores  $f_i$ , donde  $i \in \{1, \dots, 4096\}$  son valores característicos derivados de un aprendizaje profundo [15].



Este proceso identifica las características con el mayor poder de discriminación en el conjunto de datos de entrenamiento. Cuanto mayor es la diferencia de medias, más discriminativas son las características para un conjunto de datos de entrenamiento. La ventaja clave es que este proceso permite usar solo el subconjunto de  $n$  funciones con la más alta diferencias de medias en el proceso de clasificación. El vector de características más corto también tiene un poder discriminativo más alto en el conjunto de datos de entrenamiento, y existe una alta probabilidad de que sea eficiente para muestras de imágenes de pruebas nunca antes vistas.

La motivación para usar *LDA* como enfoque de reducción de características es que compararon otros algoritmos tradicionalmente utilizados para esta solicitud, como el análisis de componentes principales (*PCA*) y *ReliefF*. En la mayoría de los escenarios probados con múltiples clasificadores y múltiples métricas para evaluar los resultados, el método *LDA* propuesto supera a los otros enfoques probados.

En este estudio, el objetivo fue maximizar la precisión de la clasificación, que corresponde al número total de muestras clasificadas correctamente. Dado que los conjuntos de datos de entrenamiento y de prueba no están equilibrados con una clase dominante, el enfoque solo

en una métrica no proporcionará información completa sobre el desempeño del sistema propuesto; por lo tanto, se proporcionan también evaluación de otras métricas.

Para estudiar la efectividad del proceso de reducción de características utilizando el enfoque *LDA*, emplearon cinco métodos de clasificación diferentes. El convencional es la máquina de vectores de soporte (*SVM*), que a menudo se usa en combinación con características de aprendizaje profundo. Las principales alternativas son el análisis discriminante y el clasificador *k-NN*, donde se debe considerar un número diferente de vecinos más cercanos. Estos tres clasificadores también derivan probabilidades posteriores; por lo tanto, los usaron para derivar todas las métricas de comparación.

Las otras dos alternativas incluyen el clasificador *Bayes*, que aplica la estimación de densidad y la última opción es *AdaBoost*.

Se hicieron dos pruebas:

La primera prueba compara el efecto de la reducción de características en diferentes métricas de evaluación utilizando cuatro clasificadores diferentes: *SVM*, *k-NN*, análisis discriminante y clasificadores de *Bayes*. *AdaBoost* no se incluye aquí ya que el número total de funciones (4096) es demasiado alto para ejecutar el proceso de impulso de manera eficiente. Sin el uso del proceso de reducción de características, el clasificador de *AdaBoost* no es aplicable. Para el clasificador *k-NN*, primero debemos determinar el parámetro *k*. Como se quiere maximizar la precisión de la clasificación, se utilizó esta métrica para estudiar el efecto de varios parámetros *k*. El valor máximo más alto se alcanza para  $k = 30$ ; Por eso lo usaron en todas las pruebas para este clasificador.

Las conclusiones son válidas para otras tres métricas probadas, donde los valores pico se alcanzan casi exclusivamente para los vectores de características de menos de 200 componentes. Los valores exactos medidos para los clasificadores utilizando las 4096 características, que corresponde al enfoque sin *LDA*, se comparan con los valores medidos más altos para métricas y clasificadores individuales y con los valores medidos más altos cuando se usaron menos de 200 componentes. El resumen se presenta en la Tabla 20 y se ofrece la conclusión de que la optimización o reducción de las características empleadas conduce a los aumentos de rendimiento para todos los clasificadores probados. Es un

resultado significativo que justifica empíricamente nuestra suposición de que al disminuir el número de características empleadas, se puede lograr un mayor rendimiento del sistema de reconocimiento.

Tabla 20 Resumen de los resultados de la primer prueba de la primera columna muestra el rendimiento utilizando todas las funciones 4096 (sin *LDA*), la segunda columna es el valor más alto para la métrica y el clasificador especificados (el más alto), y la tercera columna es el valor máximo para la métrica y el clasificador especificados cuando menos de 200 funciones Se utilizan (los más altos 200). AP significa precisión media y *AUC* significa área bajo la curva *ROC* [15].

Métrica	Clasificador	Sin LDA	Más alto	Más alto 200
<b>Accuracy</b>	SVM	0.804	0.847	0.847
	K-NN	0.813	0.860	0.860
	Análisis discriminante	0.844	0.858	0.858
<b>AP</b>	Bayes	0.741	0.829	0.829
	SVM	0.449	0.553	0.553
	K-NN	0.417	0.548	0.548
<b>AUC</b>	Análisis discriminante	0.543	0.555	0.555
	SVM	0.756	0.805	0.805
	K-NN	0.750	0.790	0.789
<b>Sensibilidad</b>	Análisis discriminante	0.804	0.810	0.805
	SVM	0.453	0.554	0.553
	K-NN	0.053	0.360	0.360
<b>Especificidad</b>	Análisis discriminante	0.480	0.520	0.520
	Bayes	0.733	0.733	0.733
	SVM	0.891	0.999	0.999
	K-NN	0.999	0.999	0.999
	Análisis discriminante	0.934	0.974	0.974
	Bayes	0.743	0.967	0.967

En la segunda prueba, redujo el vector de características al máximo de 200 componentes y se evaluó todos nuestros clasificadores, incluido *AdaBoost*, utilizando las mismas métricas analizadas anteriormente. Los resultados para la precisión de la clasificación (Figura 13), la sensibilidad (Figura 14) y la especificidad (Figura 15) incluyen los cinco clasificadores probados, mientras que los resultados para la precisión promedio (Figura 16) y el área debajo de la curva *ROC* (Figura 17) es solo para *SVM*, *k-NN* y análisis discriminante como en la prueba anterior.

Figura 13 Evaluación de la precisión de la clasificación (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de entidad reducida que varía de 0 a 200 componentes (eje x) [15].




Figura 14 Evaluación de la sensibilidad (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].




Figura 15 Evaluación de la especificidad (eje y) utilizando cuatro clasificadores diferentes con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].

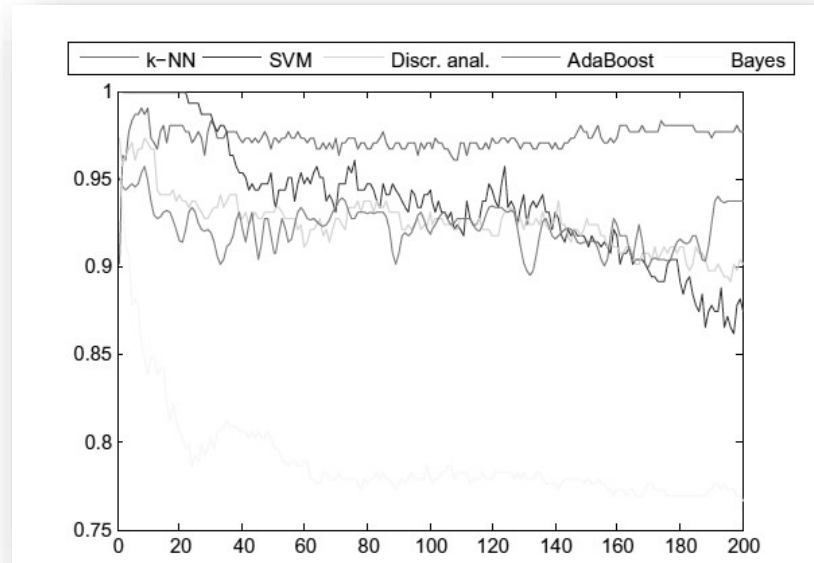


Figura 16 Evaluación de la precisión promedio (eje y) con SVM y k-NN clasificadores con longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].

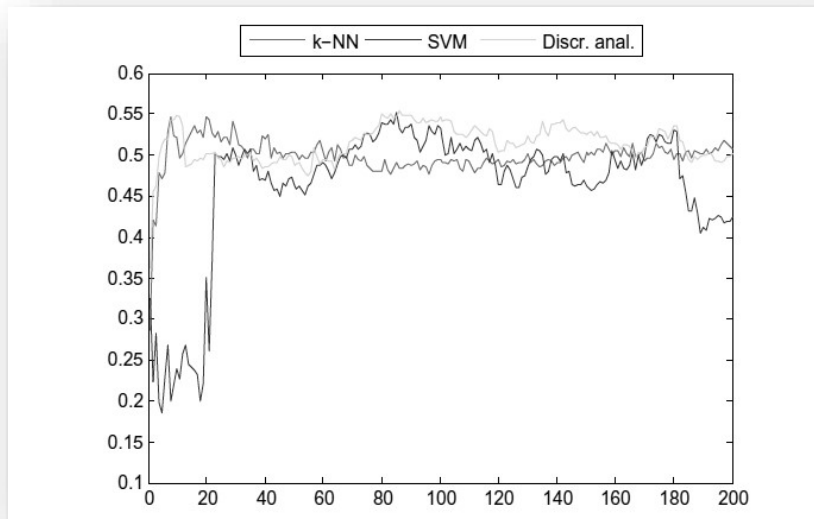





Figura 17 Evaluación del área bajo la curva *ROC* (eje y) utilizando clasificadores *SVM* y *k-NN* con una longitud de vector de característica reducida que varía de 0 a 200 componentes (eje x) [15].



La conclusión de los gráficos presentados es que diferentes clasificadores son adecuados para diferentes tareas de clasificación de melanoma. Cuando el objetivo es maximizar la sensibilidad, el clasificador de *Bayes* sería la opción óptima, pero su especificidad es menor que para los otros clasificadores. En el caso de maximizar la especificidad, sugeriríamos un clasificador *k-NN* o *SVM*. En términos de precisión promedio y área bajo la curva *ROC*, los tres clasificadores probados tienen valores máximos muy similares correspondientes a la longitud del vector de características entre 80 y 100.

Como se mencionó, el objetivo de este estudio fue maximizar la precisión de la clasificación y el clasificador con el mejor rendimiento para el problema de clasificación presentado es *k-NN* con la precisión de 0.860 para 30 componentes de vectores de características.

#### 2.6.11 Haenssle

Haenssle et al [16] usaron y entrenaron una versión modificada de la arquitectura *CNN Inception v4 de Google*.

Crearon un conjunto de pruebas de 300 imágenes que incluye un 20% de melanomas de todos los sitios del cuerpo y de todos los histotipos frecuentes, y un 80% de nevos melanocíticos

benignos de diferentes subtipos y sitios del cuerpo, incluidos los llamados "simuladores de melanoma. Las imágenes del conjunto de prueba-300 se recuperaron de la biblioteca de imágenes validadas de alta calidad del *Departamento de Dermatología de la Universidad de Heidelberg*, Alemania. Se utilizaron varias combinaciones de cámara / dermoscopia para la adquisición de imágenes. No se permitió la superposición entre conjuntos de datos para entrenamiento / validación y pruebas.

Antes de que su *CNN* se probara, dos dermatólogos experimentados seleccionaron prospectivamente 100 imágenes del conjunto de 300 para una mayor dificultad de diagnóstico. Este conjunto 100 se usó para las pruebas de *CNN* en comparación con los dermatólogos en un estudio de lectura global. Los lectores (n=172) fueron invitados a través de las listas de correo de la Sociedad Internacional de Dermatoscopia, y 58 (33.7%) devolvieron sus hojas de votación completas. Los participantes indicaron su nivel de experiencia en dermatoscopia ("Principiante" <2 años de experiencia, "Especializados" 2 - 5 años de experiencia, "Experto" 5 años de experiencia).

Configuraron dos niveles. En el nivel I del estudio, a los dermatólogos se les presentó únicamente la imagen dermatoscópica y se les pidió que indicaran su diagnóstico dicotómico (melanoma, nevo benigno) y su decisión de manejo (extirpación, seguimiento a corto plazo, envío / no se requiere acción). Después de un intervalo de 4 semanas, los mismos participantes indicaron su diagnóstico y decisión en el nivel II, que incluyó imágenes dermatoscópicas complementadas con información clínica adicional e imágenes de primeros planos de los mismos 100 casos.

Diecisiete (29.3%) de los 58 dermatólogos participantes de 17 países indicaron ser "principiantes" en dermatoscopia (<2 años de experiencia), mientras que 11 (19%) y 30 (51.7%) declararon ser "calificados" (2– 5 años de experiencia) o 'experto' (> 5 años de experiencia), respectivamente.

En el nivel I, los dermatólogos lograron una sensibilidad y especificidad medias (+desviaciones estándar) para la clasificación de lesiones de 86.6% (+9.3%) y 71.3% (+11.2%), respectivamente. Más información clínica (nivel II) mejoró la sensibilidad al 88.9% (+9.6%) y la especificidad al 75.7% (+11.7%).


La curva *CNN ROC* reveló una mayor especificidad del 82.5% en comparación con los dermatólogos en el nivel I (71.3%) y el nivel II (75.7%) en sus sensibilidades de 86.6% y 88.9%, respectivamente. El *AUC ROC* de *CNN* fue mayor que el área *ROC* media de los dermatólogos (0,86 versus 0,79).

#### 2.6.12 Kawahara

Kawahara et al [17] diseñaron una *CNN* para predecir la etiqueta de clase de lesión verdadera y, dada una imagen de lesión de piel  $x$ . Su *CNN* está compuesta por múltiples secciones donde cada sección considera la misma imagen en una resolución diferente utilizando el mismo campo de visión. Una capa final combina las respuestas de varias resoluciones en una sola capa. Adjuntaron una capa de pérdida supervisada (es decir, una capa con una función de pérdida que compara las etiquetas de clase predichas) a estas respuestas combinadas, lo que hace que la predicción final sea una función aprendida de varias resoluciones de la misma imagen. Esta pérdida es propagada a lo largo de toda la red y hace que la red se optimice con respecto a las resoluciones de múltiples imágenes. Agregaron capas de pérdida supervisadas auxiliares a cada tramo, ya que se descubrió que agregar capas adicionales supervisadas de "acompañante" / "auxiliar" regulariza las respuestas de aprendizaje.

En este trabajo, las pérdidas auxiliares hacen que cada tramo aprenda parámetros que se clasifican bien en esa resolución particular. En el momento de la prueba, ignoraron los clasificadores auxiliares y solo usaron el clasificador final. La imagen de resolución más alta  $x(I)$ , se promedia en conjunto para crear una imagen de baja resolución  $x(0)$ , como entrada al tramo superior.  $x(I)$  se alimenta al tramo inferior para extraer respuestas a una escala más fina. Como todas las capas son capas convolucionales, una entrada más grande produce respuestas más grandes (recuadro inferior verde). Después de las capas con parámetros pre-entrenados  $\theta_p$ , se agregan capas adicionales con parámetros entrenables no compartidos  $\theta_t$ . Cada tramo tiene una capa de pérdida auxiliar supervisada (caja azul). Las respuestas de ambas resoluciones de imagen se combinan y una capa de salida hace la predicción final (cuadro rosado). Las dimensiones espaciales (por ejemplo, 8 significan  $8 \times 8$ ) se dan dentro de cada cuadro, y el número de canales se muestra junto a cada cuadro. (Figura de color en línea) En la Figura 18 se puede observar la red *CNN* propuesta.

Figura 18 La red neuronal multiresolución completamente convolucional de dos vías (o dos tractos) propuesta [17].



Utilizaron *Dermofit Image Library* para probar su método. Este conjunto de datos contiene 1300 imágenes de lesiones de la piel de 10 clases: *queratosis actínica (AK)*, *carcinoma de células basales (BCC)*, *melanocítico (ML)*, *carcinoma de células escamosas (SCC)*, *queratosis seborreica (SK)*, *carcinoma intraepitelial (CE)*, *Granuloma piógeno (PYO)*, *hemangioma (VSC)*, *dermatofibroma (DF)* y *melanoma maligno (MEL)*. Dividieron al azar el conjunto de datos en tres subconjuntos de aproximadamente el mismo número de imágenes y distribuciones de clase. Un subconjunto se usa para entrenar validar y probar. Cambiaron el tamaño de la imagen  $x(0)$  a  $227 \times 227$  y  $x(1)$  a  $454 \times 454$ . Cada imagen se normalizó restando la intensidad media.

Para sus primeros experimentos (Tabla 21 filas a-c), extrajeron las respuestas de la sexta capa (FC6) de la *AlexNet* pre-entrenada para las imágenes  $x(0)$  y  $x(1)$ , y agrupando las respuestas espaciales de  $x(1)$ . Como en estas respuestas extraídas se utilizan para entrenar un clasificador de regresión logística. Informamos la precisión para clasificar  $x(0)$  y  $x(1)$  individualmente, y en las respuestas concatenadas de las dos resoluciones de imagen.

Sus próximos experimentos (filas d, e) muestran que nuestro uso híbrido de capas entrenadas con lesiones cutáneas adicionales y pre-entrenadas mejoró la precisión de la clasificación. Dividimos la red de dos vías en zonas superiores e inferiores y formamos cada una por separado en una sola resolución. Para una comparación justa, duplicamos el número de nodos en la capa antes de la capa de pérdida auxiliar (es decir, la capa naranja de la Figura 10) para

coincidir con el número de parámetros independientes dentro del modelo de dos vías. La precisión del modelo de resolución única de un solo tramo (filas *d*, *e*) mejoró con respecto a las filas a, b, pero es menor que nuestro modelo propuesto (fila *i*), lo que indica que considerar las resoluciones múltiples dentro de nuestra arquitectura de dos vías mejora la precisión.

La fila k combina vistas de imagen aumentada con entrada de resolución múltiple, lo que resulta en mejoras de precisión adicionales cuando se compara con el uso de solo vistas aumentadas (fila *j*) y el uso de resoluciones múltiples (fila *i*), destacando que la propuesta de la entrada de resolución múltiple complementa los enfoques de aumento de imagen existentes.

En la Tabla 21 se muestran todos los resultados de lo explicado anteriormente.

Tabla 21 Resultado de los experimentos [17].

	<b>Método</b>	<b>Resolución de imagen</b>	<b>Validación</b>	<b>Prueba</b>
(a)	FC6+LogReg	227	0.674	0.705
(b)	FC6+LogReg	454	0.649	0.700
(c)	Kawahara et al. 2015	227/454	0.684	0.741
(d)	1-tracto (fig. 10)	227	0.773	0.741
(e)	1-tracto (fig. 10)	454	0.737	0.759
(f)	1-tracto + Sermanet entre otros 2014	227/454	0.719	0.748
(g)	He et al. 2014	224/448	0.688	0.711
(h)	2-tractos 0-aux-losses (fig. 10) 2-tractos 2-auxiliares de perdida (fig. 10)	227/454	0.726	0.755
(i)		227/454	0.751	0.773
(j)	1-tracto (fig. 10)	0.454	0.760	0.755
(k)	2-tractos 2-auxiliares de perdida (fig. 10)	227/454	0.781	0.795

### 2.6.13 Moura

Moura et al [18], proponen la clasificación de las lesiones de la piel utilizando un descriptor formado por la combinación de las características de la regla *ABCD* (*Asimetría, Borde, Color y Diámetro*) y redes neuronales convolucionales (*CNN*) pre-entrenadas. Las características se seleccionaron de acuerdo con sus relaciones de ganancia y se usaron como entrada para el clasificador de *Perceptrón MultiLayer*. Construimos una nueva base de datos que une dos bases de datos distintas presentadas en la literatura para validar la metodología propuesta.

El objetivo de este trabajo fue diagnosticar el melanoma mediante imágenes dermatoscópicas. Para ello, se aplicaron experimentos con descriptores de textura, color y forma, así como redes neuronales convolucionales (*CNN*), a las imágenes de lesiones de la piel. Se realizó una evaluación de la posible descripción separada de cada uno de estos descriptores y se concluyó que la combinación de diferentes características conduce a tasas de clasificación de melanoma mejores y más correctas. A partir de esa información, los descriptores tenían sus vectores concatenados, formando un nuevo descriptor.

Las características son propiedades que se pueden medir a partir de una imagen, como la forma, el color y la textura. Estos atributos, agrupados en un vector de características, se denominan descriptor de imagen. Los descriptores utilizados para extraer características de las imágenes de lesiones de la piel y forman el descriptor híbrido. Los propuestos se detallan a continuación:

*Regla ABCD*: esta regla se divide en cuatro pasos para describir la imagen y tiene cinco atributos: *asimetría* (1), *irregularidad del borde* (2), *color* (1) y *diámetro* (1).

*El diámetro es la primera característica calculada*. Inicialmente, con la máscara binaria, el contorno de la lesión se obtiene mediante un algoritmo de Sobel. Luego, se calcula la distancia más grande entre dos puntos ( $p1 = (x1, y1)$  y  $p2 = (x2, y2)$ ) (diagonal mayor), que pertenece al borde de la lesión mediante el uso de la ecuación de distancia euclidiana. El resultado, en píxeles, se utiliza para la clasificación.

*La asimetría se calcula a partir del diámetro*, donde la distancia más grande, en píxeles, entre la línea (diagonal mayor) y un punto que pertenece al borde se obtiene mediante la siguiente ecuación:

$$d = \frac{|ax_0+by_0+c|}{\sqrt{a^2+b^2}} \text{-----2)}$$

Donde  $a$ ,  $b$  y  $c$  son los coeficientes de la línea y  $x_0$ ,  $y_0$  los puntos coordinados de la imagen.

*La irregularidad del borde* se calcula a partir de dos técnicas diferentes. *En la primera*, los pesos se asignan a los cuatro vecinos a la derecha e izquierda de todos los puntos del borde de la lesión. El vecino que está por encima del punto analizado se considera la coordenada y recibe un peso de -1; de lo contrario, recibe un peso de 1. Si esta suma es mayor o igual a 2, la inflexión se considera un pico; de lo contrario, si es menor o igual a -2, se considera un valle. El objetivo es descubrir el número total de picos y valles en la lesión. *En la segunda técnica*, se calculan los principales picos y valles de la lesión. El producto vectorial se usa para todos los puntos del borde de la lesión, considerando sus vecinos derecho e izquierdo ( $p - 15$ ;  $p$ ;  $p + 15$ ), donde  $p$  es el punto; es decir, una variación de 15 píxeles a la izquierda y 15 píxeles a la derecha del punto  $p$ . Por lo tanto, si el resultado del producto vectorial es mayor que cero,  $p1 = (x1, y1)$ ,  $p2 = (x2, y2)$  y  $p3 = (x3, y3)$  constituyen un pico, y si son menos de cero constituyen un valle.

En la característica de color, el número de colores encontrados en la lesión se utiliza en la clasificación. Inicialmente, dividimos los valores de píxeles de la imagen en diez intervalos (los tonos que pertenecen a la misma se consideraron similares). Para cada rango, se cuenta el número de píxeles. Sin embargo, se descartaron las regiones pequeñas (menos de 100 píxeles).

Las *CNN* se han establecido como la técnica de vanguardia más avanzada de los sistemas de visión artificial. Se han utilizado con éxito en diferentes aplicaciones, como el reconocimiento de objetos y la segmentación de imágenes para el diagnóstico médico. Los autores han presentado dos formas diferentes de usar el poder de las *CNN*:

El primero es el método habitual en el que la capacitación se realiza con un gran conjunto de datos.

El segundo es el aprendizaje por transferencia utilizando redes pre-entrenadas. En este trabajo, utilizaron *CNN* pre-entrenadas en una gran base de datos de imágenes naturales. Por lo tanto, la red neuronal puede asimilar características genéricas para facilitar su aplicación en bases de datos pequeñas. Una forma de realizar el aprendizaje por transferencia es usar la

última capa completamente conectada de la red como un vector de características. Por lo general, esta capa contiene 4.096 atributos. Esta técnica se puede utilizar para varios tipos de tareas, por ejemplo, en la extracción de características de imágenes de caras, objetos y enfermedades.

Se utilizaron siete arquitecturas recientemente propuestas para construir el enfoque.

- *AlexNet*
- *CaffeNet*
- *Vgg-f, Vgg-m and Vgg-s*
- *Vgg-verydeep-16 and Vgg-verydeep-19*

Para establecer el vector de características, realizamos dos pasos: combinación de descriptores y selección de características. Elegimos los descriptores *ABCD*, *Vgg-m*, *Vgg-s*, *Vgg-verydeep-19* y *CaffeNet* para componer el descriptor híbrido. La regla *ABCD* calcula cinco características: asimetría (1 característica), bordes irregulares (2 características), color (1 característica) y diámetro (1 característica). Las *CNN* pre-entrenadas (*Vgg-m*, *Vgg-s*, *Vgg-verydeep-19* y *CaffeNet*) devuelven 4.096 características cada una, totalizando 16,389 atributos.

Se realizó una selección de atributos con el algoritmo de información de relación de ganancia en el vector característico obtenido. Este es un filtro de atributos supervisados que se puede usar para seleccionar atributos. Este algoritmo busca seleccionar atributos que maximicen la ganancia de información mientras minimizando el número de valores de un atributo. Es muy flexible y combina varios métodos de investigación y evaluación. El método utilizado fue *Ranker*, que clasifica los atributos según sus evaluaciones individuales. En este tipo de algoritmo, se usa una puntuación para cada atributo individualmente, construyendo una clasificación que va desde los atributos más relevantes a los menos relevantes.


El software utilizado para la clasificación fue el Entorno de *Waikato* para el Análisis del Conocimiento (*WEKA*), esta herramienta ofrece un conjunto de algoritmos de aprendizaje automático para la extracción de datos, incluida la clasificación, regresión, agrupación, algoritmos de selección de características y reglas de asociación. Los algoritmos utilizados en los experimentos para este trabajo fueron la máquina de vectores de soporte (*SVM*), el



perceptrón multicapa (*MLP*) y el vecino más cercano a *K* (*KNN*) . También probamos un conjunto compuesto por *MLP*, *SVM* y *KNN* y *Random Forest*.

En las pruebas más exitosas el método propuesto logró una tasa de precisión del 94,9% usando *MPL* como observa en la Figura 19:

Figura 19 Resultados de la variación porcentual de los atributos seleccionados para el clasificador *MLP* [18].



#### 2.6.14 Olivares

Olivares et al [19] Comentan que la extracción de características para describir lesiones de la piel es un área de investigación desafiante debido a la dificultad para seleccionar características significativas.

Así que su objetivo principal de este trabajo es encontrar la mejor combinación de características, en función de las propiedades de la forma, la variación del color y el análisis de la textura, para extraerlas utilizando diversos métodos de extracción de características.

Extrajeron características relacionadas con el color y la textura. Se adoptaron diferentes categorías de clasificadores para evaluar el paso de extracción de características propuesto y se compararon varios algoritmos de selección de características para la clasificación de las lesiones cutáneas.

El sistema de diagnóstico computacional desarrollado de la lesión de la piel se aplicó a un conjunto de 1104 imágenes dermatoscópicas mediante un procedimiento de validación cruzada. Los mejores resultados se obtuvieron mediante un clasificador de bosque de

trayectoria óptima (*OPF*) con resultados muy prometedores. El sistema propuesto alcanzó una precisión del 92,3%, una sensibilidad del 87,5% y una especificidad del 97,1% cuando se utilizó el conjunto completo de características. Además, logró una precisión del 91,6%, una sensibilidad del 87% y una especificidad del 96,2%, cuando se eligieron 50 funciones utilizando un algoritmo de selección de características basado en la correlación.

Recopilaron del conjunto de datos del *ISIC*. Propusieron un enfoque de extracción de características, basado en propiedades de forma, variación de color y análisis de textura. Las características extraídas de las imágenes de lesiones de la piel deben representar clases (benigno o maligno). Además, dado que las propiedades de la forma se obtienen de los bordes de la lesión, solo las imágenes en las que la lesión se ajustó completamente dentro del marco de la imagen se seleccionaron para que las características pudieran extraerse con mayor precisión.

Se seleccionaron un total de 1104 imágenes del conjunto de datos original. De estas, 916 imágenes fueron lesiones benignas y 188 imágenes fueron lesiones malignas. Las imágenes del conjunto de datos se redimensionaron a una resolución promedio de 400 x 299 píxeles para simplificar su procesamiento. En la Tabla 22 se pueden observar los resultados.

Tabla 22 Resultados de Olivares entre otros para diferentes clasificadores [19].

<b>Clasificador</b>	<b>ACC %</b>	<b>Sensibilidad %</b>	<b>Especificad %</b>
<b>KNN</b>	75.8	69.4	82.2
<b>Bayes net</b>	68.2	54	82.4
<b>C4.5</b>	86.9	82.2	91.5
<b>MPL</b>	74.5	61.2	87.7
<b>SVM</b>	91.7	87.1	96.2
<b>OPF</b>	92.3	87.5	97.1

#### 2.6.15 Premaladha

Premaladha el at recopilaron [20] 992 imágenes de dermatoscopia de diferentes fuentes de Internet validadas. El conjunto de datos se compone tanto de melanoma como de otras imágenes de lesiones cutáneas benignas que se tomaron de diferentes pacientes. Las imágenes son adquiridas a través del dermatoscopio y también con cámara digital *Nikon D3* o *Nikon D1x* y un micro lente *Nikkon 2.8 / 105 mm*.

Proponen un sistema de diagnóstico asistido por computadora (*Computer Aided Diagnosis CAD*) que equipa algoritmos eficientes para clasificar y predecir el melanoma. La mejora de las imágenes se realiza utilizando la técnica de ecualización de histograma adaptativa limitada de contraste (*Contrast Limited Adaptive Histogram Equalization technique CLAHE*) y el filtro de mediana. Se implementó un nuevo algoritmo de segmentación llamado *Segmentación de Otsu Normalizada (NOS)* para segmentar la lesión de piel afectada de la piel normal, que supera el problema de la iluminación variable.

Quince características se derivan y se extraen de las imágenes segmentadas que se incorporan a las técnicas de clasificación propuestas, como los algoritmos de redes neuronales basadas en el aprendizaje profundo y la máquina de vectores de soporte híbrido *adaboost (SVM)*. El sistema propuesto se prueba y valida con 992 imágenes (lesiones malignas y benignas) y proporciona una alta precisión de clasificación del 92.89%, como se muestra en la Tabla 23.

Tabla 23 Resultados de Premaladha [20].

Clasificador	ACC %	Sensibilidad %	Especificad %
<b>ANN (Redes neuronales artificiales)</b>	90.12	92.65	86.86
<b>ANFIS (Sistema adaptativo de inferencia neuro-difusa)</b>	90.39	92.68	87.3
<b>SVM</b>	90.44	92.65	86.86
<b>DLNN (Aprendizaje profundo basado en redes neuronales.)</b>	92.89	94.83	90.46
<b>Real AdaBoost</b>	86.52	89.16	56.76
<b>Modest AdaBoost</b>	86.84	84.89	89.5
<b>Gentle AdaBoost</b>	89.91	92.32	86.8
<b>Hybrid AdaBoost</b>	91.7	94.08	88.71

### 2.6.16 Yuexiang

Yuexiang et al [21] propusieron dos métodos de aprendizaje profundo para abordar tres tareas principales que surgen en el área del procesamiento de imágenes de lesiones de la piel, es decir, la segmentación de lesiones (tarea 1), la extracción de características dermatoscópicas de lesiones (tarea 2) y la clasificación de lesiones (tarea 3).

Proponen un marco de aprendizaje profundo que consiste en dos redes residuales totalmente convolucionales (*Fully Convolutional Residual Networks FCRN*) para producir


simultáneamente el resultado de la segmentación y el resultado de clasificación general. Se propone una *CNN* directa para la tarea de extracción de características dermatoscópicas.

Los marcos de aprendizaje profundo propuestos se evaluaron en el conjunto de datos *ISIC*. Los resultados experimentales muestran las prometedoras precisiones de sus marcos, es decir, 0.753 para la tarea 1, 0.848 para la tarea 2 y 0.912 para la tarea 3.

Usaron 2000 imágenes de lesiones de la piel como un conjunto de entrenamiento con máscaras para la segmentación, máscaras de *superpíxeles* para la extracción de características dermatoscópicas y anotaciones para la clasificación. Las imágenes de las lesiones se clasifican en tres categorías, *Melanoma*, *Queratosis seborreica* y *nevus*. El melanoma es un tumor maligno de la piel que conduce a una alta tasa de mortalidad. Los otros dos tipos de lesiones, es decir, la queratosis seborreica y el *nevus*, son benignos.

Pre procesaron la imagen Como se ilustra en la Figura 20, este enfoque no solo amplía el área de la lesión para la detección de características, sino que también mantiene la forma de la lesión de la piel.

Figura 20 Pre procesamiento de imagen [21].



#### 2.6.17 Yu

Yu [22] (Yu, y otros, 2018) hicieron una clasificación del melanoma acral lentiginoso, ya que es el tipo más común de melanoma en los asiáticos, y generalmente resulta en un mal pronóstico debido a un diagnóstico tardío. Aplicaron una red neuronal convolucional a las imágenes de dermatoscopia de melanoma acral y nevos benignos en manos y pies y evaluaron su utilidad para el diagnóstico temprano de estas afecciones. Analizaron un total de 724

imágenes de dermatoscopia que comprendían melanoma *acral* (350 imágenes de 81 pacientes) y *nevos* benignos (374 imágenes de 194 pacientes) y confirmadas mediante examen histopatológico. Para realizar la validación cruzada doble, dividieron en dos subconjuntos mutuamente exclusivos: la mitad del conjunto de datos de la imagen fue seleccionada para el entrenamiento y el resto para la prueba, y calculamos la precisión del diagnóstico comparándolo con el dermatólogo y no expertos en evaluación. La precisión (porcentaje de verdaderos positivos y verdaderos negativos de todas las imágenes) de la red neuronal convolucional fue de 83.51% y 80.23%, que fue mayor que la evaluación de los no expertos (67.84%, 62.71%) y cercana a la de los expertos ( 81.08%, 81.64%).

#### 2.6.18 Pomponiu

Pomponiu y otros [23] utilizaron solo 399 imágenes de una cámara estándar para la clasificación de melanomas versus *nevos* benignos. En primer lugar, se realizó el aumento de datos y pre procesamiento. Posteriormente, se aplicó una *AlexNet* pre-entrenada para la extracción de características representativas. Las lesiones se clasificaron luego con un clasificador vecino más cercano utilizando métricas de distancia de coseno. El algoritmo no se probó con un conjunto de datos de prueba independiente; solo se realizó una validación cruzada. El algoritmo alcanzó una sensibilidad del 92,1%, una especificidad del 95,18% y una precisión del 93,64%.

### 2.7 Sistemas automatizados más relevantes, para la detección de melanoma.

En [31] se mencionan los siguientes sistemas para la detección de melanomas a continuación algunas de sus características.

#### 2.7.1 MoleMax™

- Es propiedad de la compañía *Derma Medical Systems (Austria)* y fue desarrollada en cooperación con la facultad de medicina de la Universidad de Viena.
- Es un sistema que ha tenido dura presencia en el mercado durante muchos años, y funciona en dermatoscópica clásica con imágenes obtenidas con hardware propietario.
- De hecho, hoy *MoleMax*™ es un estándar clínico aceptado a nivel mundial en microscopía de epiluminiscencia digital.

- Permite el análisis de imágenes macroscópicas, capturadas con cámaras digitales, y soporte para webcam.
- Se vende solo a profesionales de la salud, aunque la interacción con el sistema de usuario no médico está permitido, para la realización de la detección y, de hecho, está enfocado a la *teledermoscopia*.
- Sus el grado de penetración entre los profesionales de la salud es muy alto.
- El diagnóstico es llevado a cabo de forma automatizada, utilizando como soporte diagnóstico la Regla *ABCD* y la lista de comprobación de siete puntos.
- El software no está disponible.
- Es multiplataforma.

En la Figura 21 se muestra una imagen del sistema *Molemax*.

Figura 21 Se muestra la herramienta de software *Molemax*, integrada con sistema propietario, se tomó una captura de pantalla del software. [31].



### 2.7.2 DBDermo-Mips / DDAX

- Es propiedad de la compañía Biomips (Italia).
- Funciona en imágenes dermatoscópicas clásicas.
- *El principal valor es su gran velocidad, que ofrece la posibilidad de realizar en tiempo real análisis de las lesiones del paciente, sin la necesidad de almacenar previamente las imágenes.*
- Está dirigido solo a profesionales de la salud, siendo su nivel de penetración entre ellos alta

- El diagnóstico se lleva a cabo usando como algoritmo médico la regla *ABCD*, aunque analiza una gran cantidad de indicadores usando el mismo patrón de similitud y la propia empresa informa una precisión con una sensibilidad media del 92% y una especificidad media superior al 80%.
- Construido sobre la base del sistema *DBDermo-Mips* que ha permanecido durante muchos años en el mercado.

### 2.7.3 Fotofinder

- Es propiedad de la compañía *FotoFinder Systems Inc.* (Alemania).
- Es un sistema que funciona en imágenes dermatoscópicas clásicas obtenidas con hardware.
- Está muy extendido entre los profesionales de la salud que apuntan solo a ellos.
- Ofreciendo una gran cantidad de actuaciones, entre ellas una captura avanzada software para el *bodymapping*
- Es multiplataforma, lo que permite el uso incluso de dispositivos móviles
- Tiene como soporte diagnóstico la regla *ABCD*.
- *Sin datos recientes acerca de la precisión del software de diagnóstico*

### 2.7.4 DermaGraphix/Mirror

- Es propiedad de la compañía *Canfield Imaging Systems* (EE. UU.) .
- Es un sistema que funciona en imágenes dermatoscópicas clásicas con hardware patentado.
- Esta bastante establecido entre profesionales de la salud, principalmente en los Estados Unidos y el Reino Unido.
- El diagnóstico se lleva a cabo de forma automatizada, controlando la evolución de las lesiones en la piel y utilizando para el diagnóstico de la regla *ABCD*.
- No hay datos relevantes sobre la precisión del diagnóstico.
- El software está disponible.

### 2.7.5 SIAscopy™ Molemate

- Es propiedad de la compañía de *MedX Health Corporation* (Canadá)

- Es un sistema que funciona en imágenes dermatoscópicas multiespectrales obtenidas con hardware patentado, que se generan utilizando la tecnología SIAscopy™, y corresponden a ocho bandas de onda discretas consecutivas entre 400 y 1000 nm que penetran a una profundidad de 2 mm.
- Está dirigido solo a los profesionales de la salud, siendo alto su nivel de penetración.

#### 2.7.6 MelaFind®

- Es propiedad de la compañía *MELA Sciences Inc.* (EE. UU.) .
- Es un sistema que *funciona con imágenes dermatoscópicas multiespectrales* obtenidas con hardware patentado, correspondiente a 10 bandas espectrales distintas de 430 a 950 nm.
- *MelaFind* analiza datos mediante algoritmos propietarios que funcionan en una base de datos que contiene datos multiespectrales y diagnósticos histológicos de más de 10.000 lesiones de biopsia de más de 7,000 pacientes.
- Está dirigido solo a dermatólogos proporcionando una salida de sí o no para hacer la biopsia.
- Se considera actualmente como el más confiable sistema de diagnóstico en el mercado.
- Ha sido el primer sistema de software aceptado por la *FDA* de EE. UU.
- En febrero de 2011, *Archives of Dermatology* publicó un estudio sobre la precisión diagnóstica de *MelaFind vs dermatologists*. *MelaFind* logró una sensibilidad de más del 98% y la especificidad promedio fue del 91.5%. Ambos los parámetros fueron mejores que los diagnósticos clínicos realizados por los investigadores.

#### 2.7.7 Dermoscopix

- Es propiedad de la compañía *Dermoscopix* (Alemania).
- Admite imágenes clásicas macroscópicas y dermatoscópicas ,
- Permite su uso con cualquier combinación de cámara y dermatoscopio.
- Es multiplataforma, está dirigido a profesionales de la salud.
- El diagnóstico se realiza de forma automatizada, utilizando como algoritmo médico el *Método Menzies*.
- No hay datos recientes sobre la precisión del software de diagnóstico.



### 2.7.8 MicroDerm

- Es propiedad de la empresa *VisioMed* (Alemania).
- Está integrado con hardware. Patentado.
- Es multiplataforma, está dirigido a profesionales de la salud.
- El diagnóstico se llevado a cabo de forma automatizada, utilizando como algoritmo médico la regla *ABCD*.
- No hay datos recientes sobre su precisión.

### 2.7.9 MoleExpert

- Es propiedad de la empresa *DatInf GmbH* (Alemania).
- Tiene un soporte para imágenes macroscópicas y dermatoscópicas.
- Permite controlar la evolución entre imágenes tomadas en diferentes fechas.
- Utiliza para el diagnóstico con la regla del *ABCD*.
- Sin datos sobre su precisión.

### 2.7.10 *DermAlert*<sup>®</sup>

- Es propiedad de Western Research Company Inc. (EE. UU.).
- Funciona en imágenes macroscópicas.
- Permite la comparación entre las imágenes de las partes del cuerpo tomadas en diferentes períodos y la visualización de las diferencias existentes.
- Diagnóstico mediante la regla *ABCD*,
- Sin datos sobre su precisión.

### 2.7.11 MelApp

- Es propiedad de la compañía *Health Discovery Corporation* (US).
- *Funciona con imágenes dermatoscópicas y está disponible para Iphone y Android.*
- Es apoyada por una base de datos de imágenes sobre la cual usa reconocimiento de patrones usando la técnica de *Support Vector Machines (SVM)*,
- Utiliza la regla *ABCD*

### 2.7.12 UMSkinCheck

- Es propiedad de la Universidad de Michigan (EE. UU.).

- Funciona en imágenes macroscópicas
- Está disponible para Iphone.
- Propone un protocolo basado en la toma de 23 imágenes, que cubren todo el cuerpo, cuyo objetivo es controlar la evolución, esta es su principal innovación.

#### 2.7.13 Molemap

- Es propiedad de la compañía *Molemap* (Australia).
- Es el líder mundial de detección de melanoma para tareas de detección, con el objetivo de ayudar a identificar cáncer de piel melanoma en una etapa temprana.
- Comprende otros programas como el *Molesafe*.
- Tiene una red de centros en todo el mundo, en la que los especialistas toman las imágenes, que consisten en un escaneo completo del cuerpo del paciente, las imágenes se envían a un centro de diagnóstico, donde dermatólogos expertos analizan las imágenes y elaboran un informe.
- Tiene alta precisión, aunque no se especifican datos cuantitativos.
- Es realmente un programa de detección y está dirigido a los pacientes directamente.
- No comercializa software de diagnóstico

#### 2.7.14 Melanoscan

- Es propiedad de la compañía *Melanoscan Inc.* (EE. UU.) .
- Es un sistema de detección desarrollado recientemente, con resultados muy alentadores.
- Realiza un escaneo rápido sobre lesiones sospechosas, de las cuales obtiene imágenes más detalladas.
- Si tiene estudios previos, lleva a cabo comparaciones en tiempo real.
- Está dirigido a los pacientes directamente.
- No comercializa su software de diagnósticos
- Para el diagnóstico, utiliza el algoritmo *ABCD*.
- Tiene una sensibilidad del 75% se informa y se informa una especificidad del 73.70%.

En la Tabla 24 se muestra una comparativa de los sistemas anteriormente descritos.

Tabla 24 Comparativa de los sistemas anteriormente descritos.


Sistemas	hardware propietario	Teledermoscopia	multiplataforma	mapeo corporal	macroscópico	Dermatoscópico	multiespectral	aprobación	algoritmo médico	exactitud	base de datos
MoleMax™	X	X	X	X	X	X			ABCD/ 7 puntos lista de control	Sensibilidad 92% Específica 80%	
DBDermo-Mips/DDAX	X		X			X			ABCD		No reportado
Fotofinder			X	X		X			ABCD		
DermaGraphix-Mirror	X			X		X			ABCD		
SIAscopy™-Molemate	X						X		Proprietary algorithms		
MelaFind®	X						X	X	Proprietary algorithms	Sensibilidad 98% Específica 91.5%	1632 imágenes / 127 melanomas
Dermoscopix		X	X		X	X			Menzies método		
MicroDerm		X	X		X	X			ABCD		
MoleExpert		X	X		X	X			ABCD		
DermAlert®		X	X		X				ABCD		
MelApp		X	X		X				ABCD		
UMSkinCheck		X	X	X	X				ABCD		
Molemap	X	X		X		X			Expertos		
Melanoscan®	X			X		X			ABCD	Sensibilidad 75% Específica 73.7%	394 imágenes

## CAPÍTULO 3. PRELIMINARES

### 3.1 Inteligencia artificial, aprendizaje automático y aprendizaje profundo

Se debe definir claramente de qué estamos hablando cuando mencionamos ¿Qué es la *inteligencia artificial* (*AI Artificial Intelligence*), el aprendizaje automático (*machine learning*) y el aprendizaje profundo (*deep learning*)? [32]. (Ver Figura 22).

Figura 22 Artificial Intelligence, machine learning y deep learning [32].



“La *inteligencia artificial* nació en la década de 1950, cuando un puñado de pioneros del campo incipiente de la informática comenzó a preguntar si las computadoras podrían ser hechas para "Pensar": una pregunta cuyas ramificaciones aún estamos explorando hoy. Una definición concisa del campo sería el siguiente: el esfuerzo por automatizar las tareas intelectuales que normalmente se realizan por los humanos. Aunque la *IA* simbólica demostró ser adecuada para resolver problemas lógicos bien definidos, como jugar al ajedrez, resultó ser difícil resolver las reglas explícitas para resolver más problemas complejos y difusos, como clasificación de imágenes, reconocimiento de voz y lenguaje traducción. Surgió un nuevo enfoque para tomar el lugar simbólico de la *IA*: el aprendizaje automático. El *aprendizaje automático* surge de esta pregunta: ¿podría una computadora ir más allá de "lo que nosotros sabemos que ordenamos que se realice"? ¿Y aprender por sí mismo cómo realizar una tarea específica? ¿Podría una computadora sorprendernos? En lugar de que los programadores elaboren el procesamiento de datos reglas a mano, ¿podría una computadora aprender estas reglas automáticamente mirando los datos? Con el

*aprendizaje automático*, los humanos ingresan datos, así como las respuestas esperadas de los datos, y salen las reglas. Estas reglas se pueden aplicar a nuevos datos para producir originales respuestas. El *aprendizaje automático* solo comenzó a florecer en la década de 1990, se ha convertido en el subcampo más popular y exitoso de AI, una tendencia impulsada por la disponibilidad de hardware más rápido y conjuntos de datos más grandes. El aprendizaje automático está estrechamente relacionado a las estadísticas matemáticas, pero difiere de las estadísticas en varias formas importantes. A diferencia de las estadísticas, el aprendizaje automático tiende a tratar con conjuntos de datos grandes y complejos (como un conjunto de datos de millones de imágenes, cada una de las cuales consta de decenas de miles de píxeles) para cual análisis estadístico clásico como el análisis bayesiano sería poco práctico. El resultado, es que el *aprendizaje automático* y especialmente el aprendizaje profundo, muestran comparativamente poca teoría matemática, quizás demasiado poco, y está orientada a la ingeniería. Es una disciplina práctica en la que las ideas se prueban empíricamente más a menudo que teóricamente” [32].

*El aprendizaje profundo* es un sub campo específico del aprendizaje automático: una nueva visión de las representaciones de aprendizaje a partir de datos que ponen énfasis en el aprendizaje de capas sucesivas de cada vez más representaciones significativas. El aprendizaje profundo no es una referencia a ningún tipo de comprensión más profunda lograda por el enfoque; más bien, representa esta idea de sucesiva capas de representaciones; cuántas capas contribuyen a un modelo de los datos es llamado la profundidad del modelo. Otros nombres apropiados para el campo podrían haber sido representaciones en capas de aprendizaje y representaciones jerárquicas de aprendizaje. El moderno aprendizaje profundo a menudo implica decenas o incluso cientos de capas sucesivas de representaciones y todos aprenden automáticamente de la exposición a los datos de entrenamiento. Mientras tanto, otros enfoques para el aprendizaje automático tienden a centrarse en aprender solo una o dos capas de representaciones de los datos; Por lo tanto, a veces se les llama aprendizaje superficial. [32].

## 3.2 Python, Numpy y OpenCV

*Python* es un lenguaje de programación interpretado, orientado a objetos, de alto nivel con semántica dinámica. Sus estructuras de datos integradas de alto nivel, combinadas con la tipificación dinámica y el enlace dinámico, lo hacen muy atractivo para el desarrollo rápido de aplicaciones, así como para su uso como lenguaje de scripting o pegamento para conectar componentes existentes entre sí. La sintaxis simple y fácil de aprender de *Python* hace hincapié en la legibilidad y, por lo tanto, reduce el costo del mantenimiento del programa. *Python* admite módulos y paquetes, lo que fomenta la modularidad del programa y la reutilización del código. El intérprete de *Python* y la extensa biblioteca estándar están disponibles en forma de fuente o binario sin cargo para todas las plataformas principales, y se pueden distribuir libremente. [33].

*NumPy* es el paquete fundamental para la computación científica con *Python*. Además de sus obvios usos científicos, *NumPy* también se puede usar como un eficiente contenedor multidimensional de datos genéricos. Se pueden definir tipos de datos arbitrarios. Esto permite que *NumPy* se integre a la perfección con una amplia variedad de bases de datos. *NumPy* está bajo la licencia *BSD*, lo que permite su reutilización con pocas restricciones. [34].

*OpenCV (Open Source Computer Vision Library)* se publica bajo una licencia *BSD* y, por lo tanto, es gratis para uso académico y comercial. Tiene interfaces *C++*, *Python* y *Java* y es compatible con *Windows*, *Linux*, *Mac OS*, *iOS* y *Android*. *OpenCV* fue diseñado para la eficiencia computacional y con un fuerte enfoque en las aplicaciones en tiempo real. Escrita en *C/C++* optimizado [35].

## 3.3 Keras y TensorFlow.

*Keras*, es un marco de aprendizaje profundo para *Python* que proporciona una manera fácil de definir y capacitar a casi cualquier tipo de modelo de aprendizaje profundo. Tiene las siguientes características clave: a) *Permite que el mismo código se ejecute sin problemas en la CPU o GPU.* b) *Cuenta con una API fácil de usar que facilita la creación rápida de prototipos de modelos de aprendizaje profundo.* c) *Tiene soporte incorporado para redes convolucionales.* Se distribuye bajo la licencia permisiva del *MIT (Massachusetts Institute of Technology)*, lo que significa que se puede utilizar libremente en proyectos comerciales, es

compatible con cualquier versión de *Python* de 2.7 a 3.6 (a partir de mediados de 2017), proporciona bloques de construcción de alto nivel para desarrollar modelos de aprendizaje profundo y se basa en una biblioteca tensorial especializada y bien optimizada para hacerlo. Se maneja de manera modular; por lo tanto, varios motores *backend* diferentes se pueden conectar sin problemas a *Keras*. Actualmente, las tres implementaciones de back-end existentes son *TensorFlow*, *Theano* y *Microsoft Cognitive Toolkit (CNTK)*. En el futuro, es probable que *Keras* se amplíe para trabajar con motores de ejecución aún más profundos. [32].

*TensorFlow*, *CNTK* y *Theano* son algunas de las plataformas principales para el aprendizaje profundo en la actualidad. *Theano* (<http://deeplearning.net/software/theano>) es desarrollado por el laboratorio *MILA* en la Universidad de Montreal, *TensorFlow* ([www.tensorflow.org](http://www.tensorflow.org)) es desarrollado por *Google*, y *CNTK* (<https://github.com/Microsoft/CNTK>) está desarrollado por *Microsoft*. Cualquier fragmento de código que escriba con *Keras* puede ejecutarse con cualquiera de estos *backends* sin tener que cambiar nada en el código. A través de *TensorFlow* (o *Theano* o *CNTK*), *Keras* puede ejecutarse sin problemas tanto en las CPU como en las GPU. Cuando se ejecuta en la CPU, *TensorFlow* envuelve una biblioteca de bajo nivel para operaciones tensoriales llamada *Eigen* (<http://eigen.tuxfamily.org>). Cuando se ejecuta en la GPU, *TensorFlow* envuelve una biblioteca de operaciones de aprendizaje profundo bien optimizadas llamada *NVIDIA CUDA Deep Neural Network library (cuDNN)*. [32].

### 3.4 Tensores

En general, todos los sistemas actuales de aprendizaje automático utilizan tensores como su estructura de datos básica. Los tensores son fundamentales para el campo, tan fundamentales que el *TensorFlow* de *Google* recibió su nombre. Entonces, ¿qué es un tensor? En su núcleo, un tensor es un contenedor de datos, casi siempre datos numéricos. Entonces, es un contenedor de números. Es posible que ya esté familiarizado con las matrices, que son tensores 2D. Los tensores son una generalización de matrices de un número arbitrario de dimensiones. Hay que tener en cuenta que, en el contexto de los tensores, una dimensión a menudo se llama un eje [32].

### 3.4.1 Scalars (tensores 0D)

Un tensor que contiene solo un número se llama escalar (o tensor escalar, o tensor de 0 dimensiones, o tensor 0D); un tensor escalar tiene 0 ejes. El número de ejes de un tensor también se llama rango [32].

### 3.4.2 Tensor 2D

Una matriz de vectores es una matriz o tensor 2D. Una matriz tiene dos ejes (a menudo referidos a filas y columnas). Puedes interpretar visualmente una matriz como una cuadrícula rectangular de números. Esta es una matriz de *Numpy*:

```
>>> x = np.array([[5, 78, 2, 34, 0],
[6, 79, 3, 35, 1],
[7, 80, 4, 36, 2]])
>>> x.ndim
2
```

Las entradas del primer eje se denominan filas, y las entradas del segundo eje se denominan columnas. En el ejemplo anterior, [5, 78, 2, 34, 0] es la primera fila, y [5, 6, 7] es la primera columna [32].

### 3.4.3 Tensores 3D y tensores de dimensiones superiores.

Si empacas dichas matrices en una nueva matriz, obtienes un tensor 3D, que puedes interpretar visualmente como un cubo de números. A continuación, se muestra un tensor *Numpy* 3D:

```
>>> x = np.array([[[5, 78, 2, 34, 0],
[6, 79, 3, 35, 1],
[7, 80, 4, 36, 2]],
[[5, 78, 2, 34, 0],
[6, 79, 3, 35, 1],
[7, 80, 4, 36, 2]],
[[5, 78, 2, 34, 0],
[6, 79, 3, 35, 1],
[7, 80, 4, 36, 2]]])
```



```
[7, 80, 4, 36, 2]])  
>>> x.ndim  
3
```

Al empaquetar los tensores 3D en una matriz, puede crear un tensor 4D, y así sucesivamente. En el aprendizaje profundo, generalmente manipulará los tensores de 0D a 4D, aunque puede subir a 5D si procesa datos de video.

Un tensor se define por tres atributos clave:

1. Número de ejes (rango): por ejemplo, un tensor 3D tiene tres ejes y una matriz tiene dos ejes. Esto también se denomina *ndim* del tensor en bibliotecas de *Python* como *Numpy*.
2. Forma: esta es una *tupla* de enteros que describe cuántas dimensiones tiene el *tensor* a lo largo de cada eje. Por ejemplo, el ejemplo de matriz anterior tiene forma (3, 5) y el ejemplo del tensor 3D tiene forma (3, 3, 5). Un vector tiene una forma con un solo elemento, como (5), mientras que un escalar tiene una forma vacía, ().
3. Tipo de datos (generalmente llamado *dtype* en las bibliotecas de *Python*): este es el tipo de datos contenidos en el tensor; por ejemplo, el tipo de un tensor podría ser *float32*, *uint8*, *float64*, etc. En raras ocasiones, puede ver un tensor de carácter. Tenga en cuenta que los tensores de cadena no existen en *Numpy* (o en la mayoría de las otras bibliotecas), ya que los tensores viven en segmentos de memoria contiguos pre asignados, y las cadenas, que son de longitud variable, excluirían el uso de esta implementación.

Las imágenes suelen tener tres dimensiones: altura, anchura y profundidad de color. Aunque las imágenes en escala de grises tienen un solo canal de color y, por lo tanto, podrían almacenarse en tensores 2D, por convención, los *tensores* de imagen son siempre en 3D, con un canal de color unidimensional para imágenes en escala de grises. Por lo tanto, un lote de 128 imágenes en escala de grises de tamaño  $256 \times 256$  podría almacenarse en un tensor de forma (128, 256, 256, 1), y un lote de 128 imágenes en color podría almacenarse en un tensor de forma (128, 256, 256, 3) [32].

### 3.5 Convolución 2D

La convolución de una señal temporal o espacial con otra señal produce una versión modificada de la señal inicial, se puede decir que convolución es la mezcla de dos funciones la cual da una nueva función [36] [37] [38]. La señal modificada puede tener una mejor representación de características que la señal original adecuada para una tarea específica. Por ejemplo, al combinar una imagen en escala de grises como una señal 2D con otra señal, generalmente llamada filtro o núcleo, se puede obtener una señal de salida que contenga los bordes de la imagen original. Los bordes de una imagen pueden corresponder a límites de objetos, cambios en la iluminación, cambios en la propiedad del material, discontinuidades en profundidad, etc., que pueden ser útiles para varias aplicaciones. El conocimiento sobre las propiedades de invariancia de tiempo lineal o de invariancia de cambio de los sistemas ayuda a apreciar mejor la convolución de las señales.

Se puede expresar imágenes en escala de grises como señales 2D, para procesar esas señales a través de convolución 2D. Las imágenes pueden ser convolucionadas con la respuesta de impulso de un sistema de procesamiento de imágenes para lograr diferentes objetivos, como los siguientes:

- Eliminar el ruido visible en la imagen a través de filtros de reducción de ruido. Para ruido blanco, podemos usar un filtro gaussiano.
- Para detectar bordes, necesitamos filtros que extraigan componentes de alta frecuencia de una imagen.

Los filtros de procesamiento de imágenes se pueden considerar como sistemas de procesamiento de imágenes que son lineales e invariantes por desplazamiento. Cualquier imagen puede ser convolucionada por filtros o núcleos. Por ejemplo, cuando intentamos tomar una imagen a través de una cámara y la imagen se vuelve borrosa debido al temblor de las manos, el desenfoque introducido puede tratarse con un filtro específico.

Cualquier imagen digital es una señal discreta 2D. La convolución de una imagen  $N \times M$  2D  $x(n_1, n_2)$  con un filtro de procesamiento de imagen 2D  $(n_1, n_2)$  viene dada por

$$y(n_1, n_2) = \sum_{k_2=0}^{N-1} \sum_{k_1=0}^{M-1} x(k_1, k_2)h(n_1 - k_1, n_2 - k_2) \quad \text{-----}3)$$

Donde  $0 \leq n_1 \leq N-1$ ,  $0 \leq n_2 \leq M-1$

Los filtros de procesamiento de imágenes funcionan en la señal de una imagen en escala de grises (2D) para producir otra imagen (señal 2D). En los casos de imágenes multicanal, generalmente se utilizan filtros de procesamiento de imágenes 2D para el procesamiento de imágenes, lo que significa que uno debe procesar cada canal de imagen como una señal 2D o convertir la imagen en una imagen en escala de grises [38].

Ejemplo:

En la Figura 23 se observa una imagen rellena con sus límites de ceros, en la Figura 24 se observa el filtro que se le va aplicar a la Figura 23 y en la Figura 25 se muestra el resultado del filtro para el punto 0,6.

Figura 23 Imagen rellena con ceros en los límites [38].

0	0	0	0	0	0	0	0	0
0	1	2	3	4	5	6	7	0
0	8	9	10	11	12	13	14	0
0	15	16	17	18	19	20	21	0
0	22	23	24	25	26	27	28	0
0	29	30	31	32	33	34	35	0
0	36	37	38	39	40	41	42	0
0	43	44	45	46	47	48	49	0
0	0	0	0	0	0	0	0	0

Figura 24 Filtro [38].

0	-4	2
1	3	-2
-1	1	-1

Figura 25 Resultado del filtro para la posición 0,6 [38].

0	0	0	0	0	0	0	0	0	-4	0	2
0	1	2	3	4	5	6	7	3	0	-2	
0	8	9	10	11	12	13	-1	14	1	0	-1
0	15	16	17	18	19	20	21	0			
0	22	23	24	25	26	27	28	0			
0	29	30	31	32	33	34	35	0			
0	36	37	38	39	40	41	42	0			
0	43	44	45	46	47	48	49	0			
0	0	0	0	0	0	0	0	0			

$$I[0,6] = 6 \times 1 + 7 \times 3 + 13 \times -1 + 14 \times 1 = 28$$

Lista de varios filtros útiles de procesamiento de imágenes y sus usos:

- *Filtro medio*: Reduce el ruido gaussiano, suaviza la imagen después del muestreo ascendente
- *Filtro mediano*: Reduce el ruido de sal y pimienta
- *Filtro Sobel*: Detecta bordes en una imagen
- *Filtro gaussiano*: Reduce el ruido en una imagen
- *Filtro Canny* :Detecta bordes en una imagen
- *Filtro Wiener* :Reduce el ruido aditivo y el desenfoque [38]

### 3.6 Redes neuronales convolucionales CNN

Las redes neuronales de convolución (*CNN*) se basan en la convolución de imágenes y detectan características basadas en filtros que la *CNN* aprende a través del entrenamiento. Por ejemplo, no aplicamos ningún filtro conocido, como los que se usan para detectar bordes o para eliminar el ruido gaussiano, pero a través del entrenamiento de la red neuronal convolucional, el algoritmo aprende por sí mismo los filtros de procesamiento de imágenes que podrían ser muy diferentes de los filtros normales de procesamiento de imágenes. Para la capacitación supervisada, los filtros se aprenden de tal manera que la función de costo general se reduce tanto como sea posible. En general, la primera capa de convolución aprende

a detectar bordes, mientras que la segunda puede aprender a detectar formas más complejas que se pueden formar combinando diferentes bordes, como círculos y rectángulos, etc. La tercera capa y más allá aprende características mucho más complicadas basadas en las características generadas en la capa anterior.

Lo bueno de las redes neuronales convolucionales es la escasa conectividad que resulta de compartir el peso, lo que reduce en gran medida la cantidad de parámetros para aprender. El mismo filtro puede aprender a detectar el mismo borde en cualquier parte de la imagen a través de su propiedad de equivalencia, que es una gran propiedad de convolución útil para la detección de características [38].

Las redes neuronales convolucionales son muy similares a las redes neuronales ordinarias. Están formadas por neuronas que tienen pesos y sesgos que pueden aprender. Cada neurona recibe algunas entradas, realiza un producto de puntos y, opcionalmente, lo sigue con una no linealidad. Toda la red aún expresa una única función de puntuación diferenciable: desde los píxeles de la imagen sin procesar en un extremo hasta las puntuaciones de clase en el otro. Y aún tienen una función de pérdida (por ejemplo, *Softmax*) en la última capa (totalmente conectada) y todos los consejos que desarrollamos para aprender redes neuronales normales aún se aplican. Entonces, ¿qué cambia? Las arquitecturas de *ConvNet (CNN)* suponen explícitamente que las entradas son imágenes, lo que nos permite codificar ciertas propiedades en la arquitectura. Esto hace que la función de avance sea más eficiente de implementar y reduzca enormemente la cantidad de parámetros en la red [39].

Los siguientes son los componentes típicos de una red neuronal convolucional:

- **La capa de entrada**, mantendrá la intensidad de píxeles de la imagen sin procesar. Por ejemplo, una imagen de entrada con ancho 64, altura 64 y profundidad 3 para los canales de color Rojo, Verde y Azul (*RGB*) tendría dimensiones de entrada de  $32 \times 32 \times 3$  [38] [39].
- **La capa de convolución**, tomará imágenes de las capas anteriores y convolucionará con ellas el número especificado de filtros para crear imágenes llamadas mapas de entidades de salida. El número de mapas de características de salida es igual al número especificado de filtros [38]. Calculará la salida de las neuronas que están conectadas a las regiones locales en la entrada, cada una de las cuales calcula un

producto de puntos entre sus pesos y una pequeña región a la que están conectadas en el volumen de entrada. Esto puede resultar en un volumen como 32x32x12 si decidimos usar 12 filtros [39].

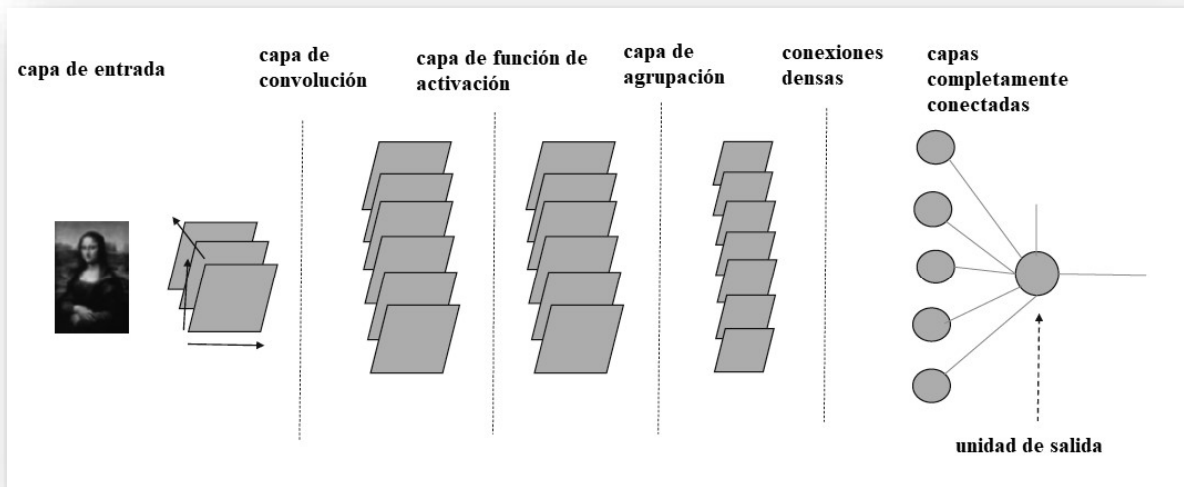
- **La capa de función de activación**, para una *CNN* son generalmente *ReLU* (Unidad lineal rectificadora) [38]. *ReLU* es uno de los elementos clave que ha revolucionado el aprendizaje profundo; es la función de activación más popular en el aprendizaje profundo, pero hay muchos otros candidatos, todos con nombres similares extraños: *prelu*, *elu*, etc. Esta capa utilizará *ReLU* como su función de activación, y la capa final puede utilizar una función de activación sigmoidea para generar una probabilidad (una puntuación entre cero y uno) [32]. La función *ReLU* transforma los valores introducidos anulando los valores negativos y dejando los positivos tal y como entran. La función *ReLU* es la siguiente [40]:

$$f(x) = \max(0, x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad \text{-----4)}$$

- **La capa de agrupación**, disminuirá los mapas de activación 2D a lo largo de las dimensiones de altura y anchura [38] [39]. La profundidad o la cantidad de mapas de activación no se ve comprometida y sigue siendo la misma [38].
- **Las capas completamente conectadas**, contienen neuronas tradicionales que reciben diferentes conjuntos de pesos de las capas anteriores. Cada neurona en esta capa se conectará a todas las neuronas en la capa anterior o a todas las salidas coordinadas en los mapas de salida a través de pesos separados. Para la clasificación, las neuronas de salida de clase reciben entradas de las capas finales completamente conectadas [38]. Esta capa calculará las puntuaciones de la clase, lo que dará como resultado un volumen de tamaño por ejemplo [1x1x10], si se tiene diez clases a clasificar [39].

En la Figura 26 se observa un diagrama de flujo básico de una red neuronal convolucional.

Figura 26 Diagrama de flujo básico de una red neuronal convolucional [38].



Cada capa puede tener parámetros o hiperparámetros de configuración, como el tamaño de las imágenes de entrada, las funciones de activación, tamaño de filtro de la convolución entre otros [39].

Existen varias arquitecturas en el campo de las redes convolucionales que tienen un nombre. A continuación se listarán algunas son:

- *LeNet* . Las primeras aplicaciones exitosas de Redes Convolucionales fueron desarrolladas por Yann LeCun en la década de 1990. De estos, el más conocido es la arquitectura LeNet que se usó para leer códigos postales, dígitos, etc.
- *AlexNet* . El primer trabajo que popularizó Convolutional Networks en Computer Vision fue AlexNet , desarrollado por Alex Krizhevsky, Ilya Sutskever y Geoff Hinton. La *AlexNet* se presentó al desafío *ImageNet ILSVRC* en 2012. La red tenía una arquitectura muy similar a la de *LeNet*, pero era más profunda, más grande y tenía capas convolucionales apiladas una encima de la otra (anteriormente, era común tener solo una capa *CONV* siempre seguida inmediatamente por una capa *POOL*).
- *ZF Net* . El ganador de la *ILSVRC 2013* fue una red convolucional de Matthew Zeiler y Rob Fergus. Llegó a ser conocido como *ZFNet* (abreviatura de Zeiler & Fergus *Net*). Fue una mejora en *AlexNet* al ajustar los hiperparámetros de la arquitectura, en particular al

expandir el tamaño de las capas convolucionales medias y hacer que la zancada y el tamaño del filtro en la primera capa sean más pequeños.

- *GoogLeNet* . El ganador de *ILSVRC* 2014 fue una red convolucional de Szegedy et al. de *Google*. Su principal contribución fue el desarrollo de un Módulo de Inicio que redujo drásticamente el número de parámetros en la red. También hay varias versiones de seguimiento para *GoogLeNet*, más recientemente, *Inception-v4* [39].

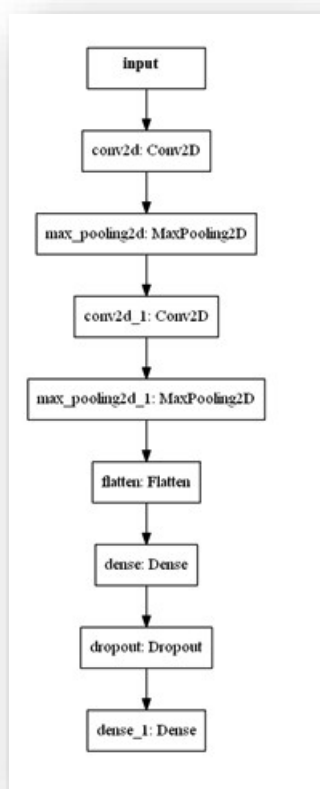
Cabe mencionar que se puede usar el entrenamiento de alguna de estas redes para usarlas en nuestros proyectos



## CAPÍTULO 4. METODOLOGÍA

Para este trabajo, se obtuvieron imágenes de *ISIC*, un repositorio de imágenes de melanomas y metadatos en "<https://isic-archive.com/>". Con las imágenes se aplicaron tres técnicas. En cada técnica se utilizó una *CNN*, la arquitectura de esta se observa en la Figura 27, la cual se usó para todas las pruebas.

Figura 27 Arquitectura de red para las pruebas.



### 4.1. Técnica 1.


Para esta técnica se agregaron datos de edad, sexo y tamaño del melanoma directamente a las 600 imágenes, duplicando estos datos en forma de píxeles, se hicieron pruebas con dos conjunto de datos, 600 con metadatos y otras 600 sin metadatos, usando las mismas imágenes, en la Tabla 25 se observa una descripción de estos conjuntos.

Tabla 25 Descripción de conjuntos de datos con y sin metadatos, las imágenes son las mismas

Paquetes	Conjunto	Tipo de Melanoma	Imágenes
Imágenes sin metadatos	Entrenamiento	Melanomas Benignos	200
		Melanomas Malignos	200
	Validación	Melanomas Benignos	100
		Melanomas Malignos	100
Imágenes con metadatos	Entrenamiento	Melanomas Benignos	200
		Melanomas Malignos	200
	Validación	Melanomas Benignos	100
		Melanomas Malignos	100

En la Figura 28 se muestran las imágenes con metadatos y sin metadatos. En a) se muestran las imágenes originales desde *ISIC* mientras que en b) se muestran las imágenes con los metadatos añadidos repetidamente en las últimas 50 filas, por lo que, se puede ver la banda de colores en cada imagen.

Figura 28 a) Matriz de imágenes sin metadatos. b) Matriz de imágenes con metadatos



Tendremos 8 épocas que es número de veces que la *CNN* va iterar sobre el conjunto de imágenes durante el entrenamiento, se usaron dos convoluciones, altura y longitud de la imágenes igual 300, 128 de imágenes a procesar en cada uno de los pasos (*batch\_size*), 1000 de pasos de entrenamiento (*step\_train*), (*step\_validation*)300 pasos de validación (al final de cada época se van a correr 200 pasos de validación para observar el aprendizaje de la *CNN*), 16 filtros en la convolución 1 (*filter\_Conv1*), 32 filtros en la convolución 2 (*filter\_Conv2*), tamaño de filtro en la convolución 1 es de 3,3 (*size\_Filter1*) y el tamaño del filtro en la convolución 2 es de 2,2 (*size\_Filter2*), tamaño de agrupamiento será de 2,2 (*size\_Pool*) este es el tamaño del filtro que se usara en nuestra capa de agrupamiento, la capa de agrupamiento son un filtros agrupados, existen dos el agrupamiento máximo (*max\_pooling*) y el agrupamiento promedio (*average\_pooling*), se usó agrupamiento máximo. Se usaron dos clases malignas y benignas. En la Figura 27 se observa la arquitectura de la *CNN* (usada en

todas las técnicas), se puede observar las dos capas de convolución con su respectiva capa de agrupamiento. Después se tiene el *flatten* para hacer las imágenes planas, es decir en una sola dimensión, el cual contiene toda la información de la *CNN*. A continuación está el cuadro de *dense* que es un capa densa de neuronas en este caso 256 con una función de activación *relu* (unidad lineal rectificadora), ahora se tiene un *dropout* (abandono) esto se usa para no ocupar todas las neuronas de esta capa, en nuestro caso solo ocupamos el %50 de las neuronas, esto es una técnica para mejorar el aprendizaje de la red. Por último se tiene el cuadro *dense\_1*, la cual es nuestra última capa de neuronas y solo contendrá dos neuronas las cuales corresponden a las clases con una función de activación *sigmoide*. La función de pérdida fue *categorical\_crossentropy*.

La penúltima capa *dense* usarán *relu* como su función de activación, y la capa final *dense\_1* usará una activación *sigmoide* para generar una probabilidad (una puntuación entre 0 y 1, que indica la probabilidad de que la muestra tenga el objetivo "1": la probabilidad de la revisión es positiva. Una *relu* es una función destinada a poner a cero los valores negativos mientras que una *sigmoide* "aplata" valores arbitrarios en el intervalo [0, 1]), generando algo que puede interpretarse como una probabilidad (Chollet, 2018).

Una vez que se hizo en entrenamiento de la *CNN* sin metadatos, se obtuvieron los resultados que se muestran en la Tabla 26 en la que se observan los resultados sin metadatos; *Acc* se refiere al accuracy (precisión) de 99.40%, *Val\_Acc* del 6.00% a la precisión de la validación, por otro lado un 0.0177 del valor de *Loss* se refiere a la función de pérdida, y un 2.7167 de *Val\_loss* a la función de pérdida de la validación.

Tabla 26 Resultados sin metadatos

Epoca	Acc	Val_Acc	Loss	Val_loss
1	0.8055	0.685	0.5772	0.8927
2	0.9461	0.65	0.1486	1.3144
3	0.9825	0.65	0.0565	1.7903
4	0.99	0.62	0.0326	2.0152
5	0.9905	0.655	0.0304	2.0311
6	0.9919	0.66	0.0243	2.5044
7	0.9933	0.65	0.0221	2.2889
8	0.994	0.64	0.0177	2.7167

En la Figura 29 y en la Figura 30 se observan las gráficas de la Tabla 26. En la Figura 29 se observa el *Acc* tiende a 1 mientras que el *Val\_acc* tiende a 0.65. En la Figura 30 se observa *Loss* tiende a 0 mientras que el *Val\_loss* incrementa hasta 2.7.

Figura 29 Gráfica de *Acc* y *Val\_acc* de la técnica 1 sin metadatos

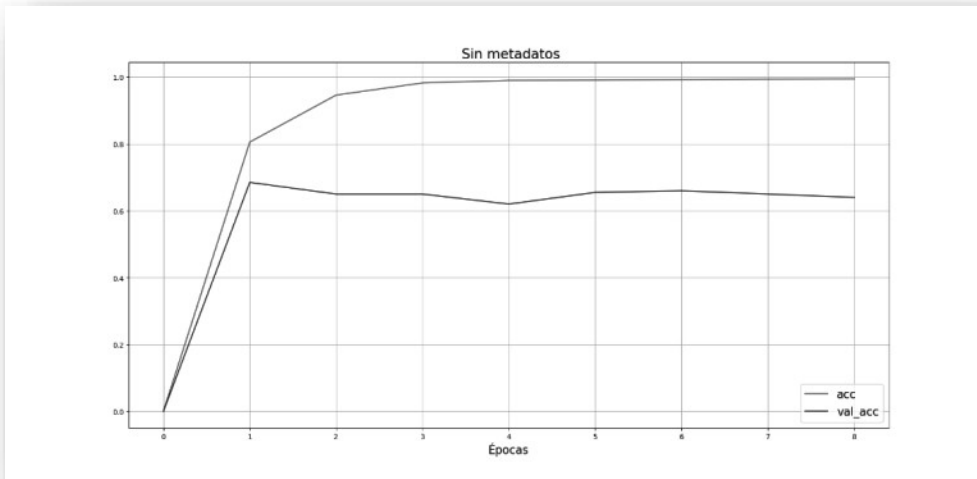



Figura 30 Gráfica de *Loss* y *Val\_loss* de la técnica 1 sin metadatos



Una vez que se hizo en entrenamiento de la *CNN* con metadatos, se obtuvieron los resultados que se muestran en la Tabla 27 en la que se observan los resultados sin metadatos; *Acc* de 99.50%, *Val\_Acc* del 80.0% a la precisión de la validación, por otro lado un 0.0134 del valor de *Loss* se refiere a la función de pérdida, y un 1.549 de *Val\_loss* a la función de pérdida de la validación.

Tabla 27 Resultados con metadatos

Época	Acc(precision)	Val_Acc	Loss	Val_loss
1	0.08727	0.785	0.3189	0.5747
2	0.9628	0.77	0.0996	0.9277
3	0.9808	0.785	0.0558	1.205
4	0.9889	0.795	0.0341	1.291
5	0.9928	0.79	0.0212	1.2993
6	0.9906	0.825	0.0279	1.2401
7	0.9948	0.765	0.0153	1.6071
8	0.9954	0.805	0.0135	1.549

En la Figura 31 y en la Figura 32 se observan las gráficas de la Tabla 27 En la Figura 5 se observa el *Acc* tiende a 1 mientras que el *Val\_acc* tiende a 0.85. En la Figura 6 se observa *Loss* tiende a 0 mientras que el *Val\_loss* incrementa hasta 1.6.

Figura 31 Gráfica de *Acc* y *Val\_acc* de la técnica 1 con metadatos


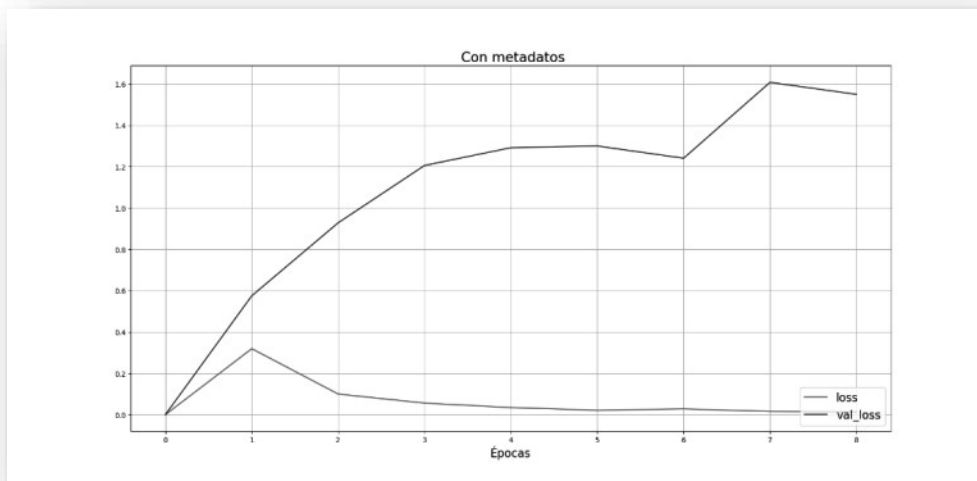


Figura 32 Gráfica de *Loss* y *Val\_loss* de la técnica 1 con metadatos




Finalmente, se hicieron pruebas con 40 imágenes (20 con metadatos y 20 sin metadatos, 10 malignas y 10 benignas para cada caso) no incluidas en la capacitación o validación y los resultados fueron una precisión 77.5% en el escenario sin metadatos y 77.5% en el escenario con metadatos.

#### 4.2. Técnica 2.

Para la siguiente técnica se quitó la piel a las lesiones, se usaron 400 para el entrenamiento; 200 malignas y 200 benignas. Para la validación se usaron 200 imágenes 100 malignas y 100 benignas. Para detectar la piel, se usó *opencv* (la cual es una librería de visión artificial), Primero, convertimos la imagen del espacio de color *RGB* al espacio de color *HSV*. Luego, aplicamos la función *cv2.inRange*, que proporciona nuestro marco *HSV*, y nuestros límites inferior y superior como argumentos, respectivamente. La salida de la función *cv2.inRange* es nuestra máscara. Esta máscara es una imagen de un solo canal, tiene el mismo ancho y alto que el marco, y es del tipo de datos enteros sin signo de 8 bits. Los píxeles que son blancos (255) en la máscara representan áreas del marco que son la piel. Los píxeles que son negros (0) en la máscara representan áreas que no son piel. Sin embargo, podemos detectar muchas pequeñas regiones de piel falsas positivas en la imagen. Para eliminar estas pequeñas regiones, primero, creamos un núcleo estructura elíptica. Luego, usamos este núcleo para realizar dos iteraciones de erosiones y dilataciones, respectivamente. Estas erosiones y dilataciones ayudarán a eliminar las pequeñas regiones de piel falsas positivas de la imagen.

A partir de ahí, suavizamos la máscara ligeramente utilizando un *desenfoque gaussiano*. Este paso de suavizado, aunque no es crítico para el proceso de detección de la piel, produce una máscara mucho más limpia. Luego aplicamos la máscara de piel a nuestro marco [41]. Se utiliza esta imagen que tiene la piel detectada para, restársela a la imagen original y solo queda solo con la lesión. En la Figura 33 se pueden observar ejemplos de algunas imágenes con las lesiones sin piel.

Figura 33 Ejemplo de imágenes sin piel



Los parámetros para prueba fueron los siguientes: *epocas*=8 *longitud*, *altura* = 300, *ancho* = 300, *batch\_size* = 32, 1000 *pasos\_validacion* = 600, *filtrosConv1* = 32 *filtrosConv2* = 64, *tamano\_filtro1* = (3, 3) *tamano\_filtro2* = (2, 2), *size\_pool* = (2, 2). Una vez que se hizo en entrenamiento de la *CNN*, se obtuvieron los resultados que se muestran en la Tabla 28 en la que se observan los resultados sin metadatos; *Acc* de 99.54%, *Val\_Acc* del 65.51% a la precisión de la validación, por otro lado un 0.0111 del valor de *Loss* se refiere a la función de pérdida, y un 2.98 de *Val\_loss* a la función de pérdida de la validación.

Tabla 28 Resultados de imágenes sin piel

Epoch	Acc	Val_Acc	Loss	Val_loss
1	0.8585	0.6798	0.3264	0.3264
2	0.9769	0.6598	0.0686	1.7079
3	0.9873	0.6702	0.0359	1.8166
4	0.9898	0.6201	0.0269	2.1192
5	0.9926	0.6449	0.0202	2.2588
6	0.9937	0.6350	0.0172	2.5145
7	0.9942	0.6900	0.0163	2.5394
8	0.9954	0.6551	0.0111	2.9813

En la Figura 34 y en la Figura 35 se observa las gráficas de la Tabla 28. En la Figura 8 se observa el *Acc* tiende a 1 mientras que el *Val\_acc* tiende a 0.65. En la Figura 9 se observa *Loss* tiende a 0 mientras que el *Val\_loss* incrementa hasta 2.9.

Figura 34 Gráfica de *Acc* y *Val\_acc* de la técnica 2 imágenes sin piel


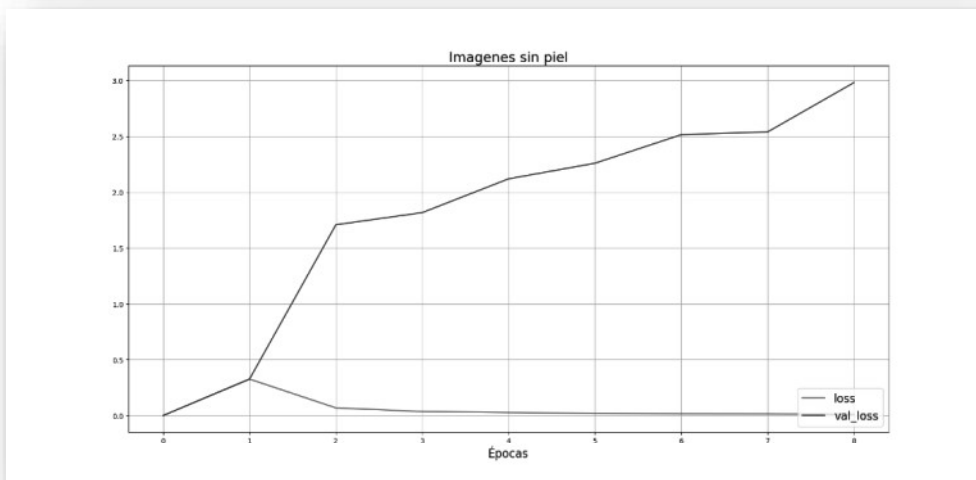


Figura 35 Gráfica de *Loss* y *Val\_loss* de la técnica 2 imágenes sin piel




Finalmente, se hicieron pruebas con 40 (20 malignas y 20 benignas) imágenes no incluidas en la capacitación o validación y los resultados fueron  $Acc=67.5\%$ .



### 4.3. Técnica 3

Para la siguiente esta técnica se usaron los siguientes parámetros: 1200 imágenes (600 malignas y 600 benignas) de entrenamiento. 400 imágenes de validación (400 malignas y 400 benignas), se aumentó la cantidad de imágenes. longitud,  $altura = 300$ ,  $300\ batch\_size = 20\ pasos = 1000\ pasos\_validacion = 300\ filtrosConv1 = 32\ filtrosConv2 = 64$ . En la Figura 36 se observa un ejemplo de las imágenes utilizadas para la técnica 3.

Figura 36 Ejemplo de imágenes de la técnica 3



Una vez que se hizo en entrenamiento de la *CNN*, se obtuvieron los resultados que se muestran en la Tabla 29 en la que se observan los resultados sin metadatos; *Acc* de 94.89%, *Val\_Acc* del 82.25% a la precisión de la validación, por otro lado un 0.1313 del valor de *Loss* se refiere a la función de perdida, y un 0.75 de *Val\_loss* a la función de pérdida de la validación.

Tabla 29 Resultados de la prueba 3

Épocas	ACC	VAL_ACC	Loss	Val_loss
1	0.7160	0.8100	0.6311	0.4821
2	0.7701	0.8725	0.4622	0.3744
3	0.8108	0.8650	0.4016	0.3667
4	0.8517	0.8325	0.3301	0.4619
5	0.8863	0.8525	0.2695	0.5041
6	0.9152	0.8475	0.2097	0.617
7	0.9361	0.7825	0.1678	0.7229
8	0.9489	0.8225	0.1313	0.7594

En la Figura 37 y en la Figura 38 se observa las gráficas de la Tabla 29. En la Figura 37 se observa el *Acc* tiende a 1 mientras que el *Val\_acc* tiende a 0.80. En la Figura 38 se observa *Loss* tiende a 0 mientras que el *Val\_loss* incrementa hasta 0.7.

Figura 37 Gráfica de *Acc* y *Val\_acc* de la técnica 3 aumentó de imágenes

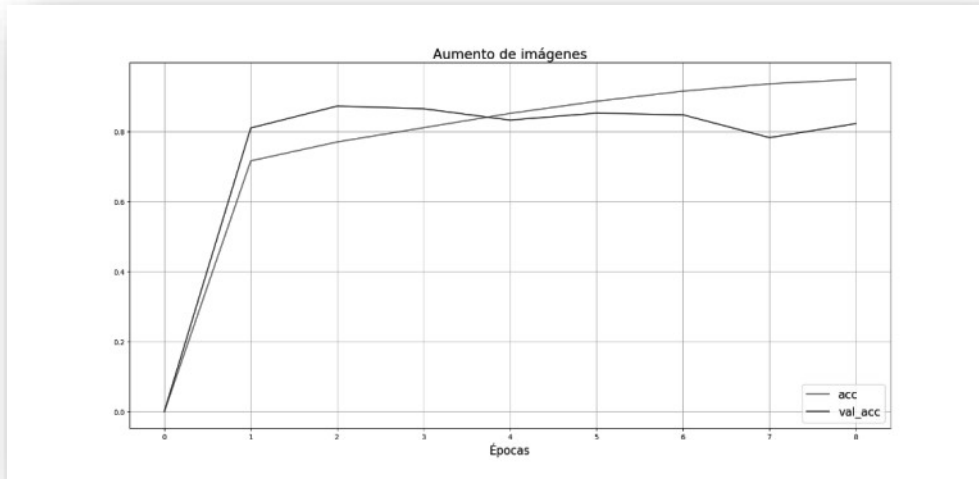



Figura 38 Gráfica de *Loss* y *Val\_loss* de la técnica 3 aumentó de imágenes



Finalmente, se hicieron pruebas con 40 (20 malignas y 20 benignas) imágenes no incluidas en la capacitación o validación y los resultados fueron  $Acc=80\%$

#### 4.8 Técnica 4 explorando más épocas con imágenes más pequeñas

Para la siguiente prueba se utilizaron los siguientes parámetros: 180 imágenes (90 malignas y 90 benignas) de entrenamiento. 40 imágenes de validación imágenes (20 malignas y 20 benignas) con un tamaño de 100 píxeles de alto x 100 píxeles,  $\text{épocas}=1000$ ,  $\text{batch\_size} = 2$ ,  $\text{pasos} = 300$ ,  $\text{pasos\_validacion} = 150$ ,  $\text{filtrosConv1} = 8$ ,  $\text{filtrosConv2} = 8$ . Se obtuvieron los siguientes resultados para la época número 1000:

loss: 5.4563e-05 - acc: 1.0000 - val\_loss: 0.4999 - val\_acc: 0.9533

Finalmente, se hicieron pruebas con 40 (20 malignas y 20 benignas) imágenes no incluidas en la capacitación o validación y los resultados fueron  $\text{Acc}=90\%$

## CAPÍTULO 5. RESULTADOS Y CONCLUSIONES

Una vez obtenidas las salidas de los algoritmos podemos resumir que: durante el entrenamiento las técnicas arrojaron las siguientes salidas: 99.40% sin metadatos, 99.54% con metadatos, 99.54% sin la piel, 94.89 con más imágenes y 100% con más capas e imágenes más pequeñas. Por otro lado, en la validación se observaron las siguientes salidas: el 64.00% sin metadatos, 80.50 con metadatos, 65.51% sin la piel, el 82.25% con más imágenes y 95% con más capas e imágenes más pequeñas. Con estas salidas podríamos concluir que las mejores técnicas es cuando se agregaron metadatos en las imágenes y cuando se incrementó el número de capas reduciendo las imágenes. Sin embargo, se hicieron pruebas con imágenes que no estuvieron presente durante el entrenamiento ni durante la validación y se obtuvieron las siguientes salidas: el 77.50% sin metadatos, el 77.50% con metadatos, el 67.50 sin piel, el 80.00% con más imágenes y 90 % con más capas e imágenes reducidas. Por lo que, se puede concluir que la mejor técnica fue al añadir más capas y reduciendo las imágenes a la *CNN*. Además la tendencia de del *Accuracy* es creciente y podría aplicarse más épocas y podría mejorar el 90% obtenido. Por lo tanto, se puede concluir que el uso de una *CNN* no requiere pre procesamiento especial en las imágenes y que basta usar el mayor número posible de imágenes así como de épocas con la finalidad de encontrar el mejor desempeño. Con un desempeño optimo, se puede hacer un sistema para poder ayudar a pre diagnosticar una lesión de manera oportuna.

En la Tabla 30 se muestran los resultados comparativos de las cuatro técnicas usadas, y otros trabajos.

Tabla 30 Comparativa de las tres técnicas con otros trabajos

<b>Nuestros resultados y otros trabajos de investigación.</b>	<b>ACC</b>	<b>VAL_ACC</b>
<b>1 Sin metadatos</b>	0.99	0.64
<b>1 Con metadatos</b>	0.99	0.805
<b>2 Sin piel</b>	0.99	0.6551
<b>3 Aumento de imágenes</b>	0.94	0.8225
<b>4 Aumento de capas</b>	1	0.9533
<b>Otros trabajos</b>	<b>ACC</b>	<b>VAL_ACC</b>
<b>Mahbod</b>	0.89	-
<b>Shoieb</b>	0.94	-
<b>Yu</b>	0.83	-
<b>Pomponiu</b>	0.93	-
<b>Codella (Codella, Cai, &amp; Garnavi, 2015)</b>	0.91	-
<b>Dorj</b>	0.94	-


En la Tabla 31 se muestran los resultados comparativos de las cuatro técnicas usadas, con imágenes nunca vista por el entrenamiento o validación de la *CNN*.

Técnica	ACC
1 Sin metadatos	0.775
1 Con metadatos	0.775
2 Sin piel	0.675
3 Aumento de imágenes	0.80
4 Aumento de capas	0.90

## 5.1 Exportando el modelo y el peso a una Raspberry Pi 3 Model B

*Raspberry* es una placa computadora de bajo coste desarrollada en el Reino Unido por la *Fundación Raspberry Pi*, con el objetivo de estimular la enseñanza de la informática en las escuelas. La placa *Raspberry Pi 3 Model B* es la tercera generación de *Raspberry Pi* [42]. En la Figura 39 se muestra una *Raspberry Pi 3*.

Figura 39 *Raspberry Pi 3*



### ***Instalación de opencv como se muestra a continuación:***

Paso 1: Expandir el sistema de archivos.

Escriba el siguiente comando para expandir el sistema de archivos *Raspberry Pi3*.

```
sudo raspi-config
```

Luego seleccione lo siguiente:

Opciones avanzadas> A1 Expandir sistema de archivos> Presionar "*Enter*".

Mostrará un mensaje "La partición raíz ha sido redimensionada".

Luego, debe reiniciar su *pi* con el siguiente comando.

```
sudo shutdown -r now
```

Paso 2: Liberar espacio.

El sistema operativo predeterminado tomará alrededor del 15% si está utilizando una tarjeta de 32 GB. Pero si está utilizando una tarjeta de memoria de 8 GB, podría ocupar el 50% de todo su espacio. Por lo tanto, es mejor eliminar algunos paquetes no utilizados como *LibreOffice* y el motor *Wolfram* para liberar espacio en su *pi* (*Raspberry Pi*).

Puede hacerlo simplemente escribiendo el siguiente comando en la ventana de terminal.

```
sudo apt - get purge wolfram - engine
```

```
sudo apt - get purge libreoffice*
```

```
sudo apt - get clean
```

```
sudo apt - get autoremove
```

Paso 3: Instalar dependencias.

El primer paso es actualizar y actualizar los paquetes existentes:

```
sudo apt-get update
```

```
sudo apt-get upgrade
```

Si se le ha mostrado algún error para corregir, puede escribir lo siguiente:

```
sudo apt - get upgrade -- fix - missing
```

Luego reiniciar su *pi*.

```
sudo shutdown - r now
```

Después de que tu *pi* se inicie, iniciar la *Terminal* nuevamente. Hacer lo siguiente:

Instalar paquetes de desarrollador *CMAKE*.

```
sudo apt-get install build-essential cmake pkg-config -y
```

Instalar paquetes de *E/S* de imagen.

```
sudo apt-get install libjpeg-dev libtiff5-dev libjasper-dev  
libpng12-dev -y
```

Instalar paquetes de *E/S* de video.

```
sudo apt-get install libavcodec-dev libavformat-dev  
libswscale-dev libv4l-dev -y
```

```
sudo apt-get install libxvidcore-dev libx264-dev -y
```

Instale la biblioteca de desarrollo *GTK* para ventanas *GUI* básicas.

```
sudo apt-get install libgtk2.0-dev libgtk-3-dev -y
```

Instalar paquetes de optimización (operaciones de matriz mejoradas para *OpenCV*).

```
sudo apt-get install libatlas-base-dev gfortran -y
```

Paso 4: Instale *Python 3*, *setuptools*, *dev* y *numpy*.

Instalar *Python 3* y *numpy*.

```
sudo apt-get install python3 python3-setuptools python3-dev -  
y
```

```
wget https://bootstrap.pypa.io/get-pip.py
```

```
sudo python3 get-pip.py
```

```
sudo pip3 install numpy
```

Paso 5: descargue los módulos adicionales de *OpenCV 3.4* y *contrib*.

```
cd ~
```

```
wget -O opencv.zip  
https://github.com/Itseez/opencv/archive/3.4.0.zip
```

```
unzip opencv.zip
```

```
wget -O opencv_contrib.zip
```

```
https://github.com/Itseez/opencv_contrib/archive/3.4.0.zip
```

```
unzip opencv_contrib.zip
```

**Paso 6: compile e instale *OpenCV 3.4.0* para *Python 3*.**

```
cd opencv-3.4.0
```

```
mkdir build
```

```
cd build
```

```
cmake -D CMAKE_BUILD_TYPE=RELEASE \
```

```
-D CMAKE_INSTALL_PREFIX=/usr/local \
```

```
-D BUILD_opencv_java=OFF \
```

```
-D BUILD_opencv_python2=OFF \
```

```
-D BUILD_opencv_python3=ON \
```

```
-D PYTHON_DEFAULT_EXECUTABLE=$(which python3) \
```

```
-D INSTALL_C_EXAMPLES=OFF \
```

```
-D INSTALL_PYTHON_EXAMPLES=ON \
```

```
-D BUILD_EXAMPLES=ON\
```

```
-D OPENCV_EXTRA_MODULES_PATH=~/.opencv_contrib-3.4.0/modules \
```

```
-D WITH_CUDA=OFF \
```

```
-D BUILD_TESTS=OFF \
```

```
-D BUILD_PERF_TESTS= OFF ..
```

**Paso 7: intercambie el tamaño del espacio antes de compilar para agregar más memoria virtual.**



Permitirá que *OpenCV* compile con los cuatro núcleos de *Raspberry Pi* sin problemas de memoria.

```
Abra su / etc / dphys-swapfile y luego edite la variable  
CONF_SWAPSIZE
```

```
sudo nano /etc/dphys-swapfile
```

Se abrirá el editor nano para editar *CONF\_SWAPSIZE*. Cámbiar como a continuación:

```
set size to absolute value, leaving empty (default) then uses  
computed value
```

```
# you most likely don't want this, unless you have an special  
disk situation
```

```
# CONF_SWAPSIZE=100
```

```
CONF_SWAPSIZE=1024
```

Luego guarde los cambios que ha realizado, presione *Ctrl + O*. Para salir de nano, escriba *Ctrl + X*. Si le pide a nano que salga de un archivo modificado, le preguntará si desea guardarlo. Simplemente presionar *N* en caso de que no lo haga, o *Y* en caso de que lo haga. Luego le pedirá un nombre de archivo. Solo escríbelo y presiona *Enter*.

Luego escriba las siguientes líneas para que tenga efecto

```
sudo /etc/init.d/dphys-swapfile stop
```

```
sudo /etc/init.d/dphys-swapfile start
```

Paso 7: finalmente listo para ser compilado.

Escriba el siguiente comando para compilarlo con 4 núcleos de *pi*.

```
make -j4
```

Paso opcional: compilar con un solo núcleo de *pi*.

Si encuentra algún error durante la compilación debido a un problema de memoria, puede comenzar la compilación nuevamente con un solo núcleo utilizando el siguiente comando:

```
make clean
```

```
make
```

Paso 8: Instale la compilación en *pi*.

Después de la compilación exitosa, instalar la compilación usando el siguiente comando:

```
sudo make install
```

```
sudo ldconfig
```

Paso 9: Verificar la compilación de *OpenCV*.

Después de ejecutar *make install*, los enlaces de *OpenCV + Python* deben instalarse en *usr*.  
/ local / lib / python3.5 / dist-packages o usr / local / lib  
/ python3.5 / site-packages .

Necesita usar los paquetes de sitio o los paquetes *dist* . Mire dónde se ha creado y use esos paquetes de sitio o paquetes de *dist* . En mi caso está en *dist-packages* .

De nuevo, puede verificar esto con el comando *ls*:

```
ls -l /usr/local/lib/python3.5/dist-packages/
```

Buscar un nombre como *cv2.so* y si no está allí, buscar un nombre como *cv2.cpython-35m-arm-linux-gnueabi.so* (nombre que comienza con *cv2*. Y termina con *.so*). Puede suceder debido a algunos errores en la biblioteca de enlace de *Python* para *Python 3*.

Se necesita cambiar el nombre de *cv2.cpython-35m-arm-linux-gnueabi.so* a *cv2.so* usando el siguiente comando:

```
cd /usr/local/lib/python3.5/dist-packages/
```

```
sudo mv /usr/local/lib/python3.5/dist-packages/cv2.cpython-35m
```

Paso 10: ¡No olvidar volver a cambiar el tamaño de tu intercambio!

Abra su / etc / dphys-swapfile y luego edite la variable  
CONF\_SWAPSIZE

```
sudo nano /etc/dphys-swapfile
```

Se abrirá el editor nano para editar `CONF_SWAPSIZE` . Cambiar como a continuación:

```
# set size to absolute value, leaving empty (default) then
uses computed value
# you most likely don't want this, unless you have an special
disk situation
CONF_SWAPSIZE = 100
# CONF_SWAPSIZE=1024
```

Luego guardar los cambios que ha realizado, presione `Ctrl + O`. Para salir de nano, escriba `Ctrl + X`. Si le pide a nano que salga de un archivo modificado, le preguntará si desea guardarlo. Simplemente presione `N` en caso de que no lo haga, o `Y` en caso de que lo haga. Luego le pedirá un nombre de archivo. Solo escríbelo y presiona `Enter`.

Luego escriba las siguientes líneas para que tenga efecto.

```
sudo /etc/init.d/dphys-swapfile stop
sudo /etc/init.d/dphys-swapfile start [42]
```

### **Instalación de *Tensorflow* y *Keras*.**

Para instalar *Tensorflow* en nuestra *Raspberry Pi*, usaremos *pip* y lo instalaremos directamente desde un archivo *whl* que obtendremos de <https://github.com/lhelontra/tensorflow-on-arm>. Específicamente, instalaremos la versión 1.13.1.

Para instalar *Tensorflow* directamente desde esta fuente, simplemente podemos ejecutar:

```
pip3 install https://github.com/lhelontra/tensorflow-on-
arm/releases/download/v1.13.1/tensorflow-1.13.1-cp35-none-
linux_armv7l.whl
```

**Ahora, para continuar con *Keras*, instalaremos algunas (más) dependencias y una actualización:**

```
sudo apt-get install libblas-dev liblapack-dev gfortran
```

```
sudo apt-get install python3-dev python3-setuptools
```

```
sudo apt-get install python3-numpy python3-scipy python3-h5py
```

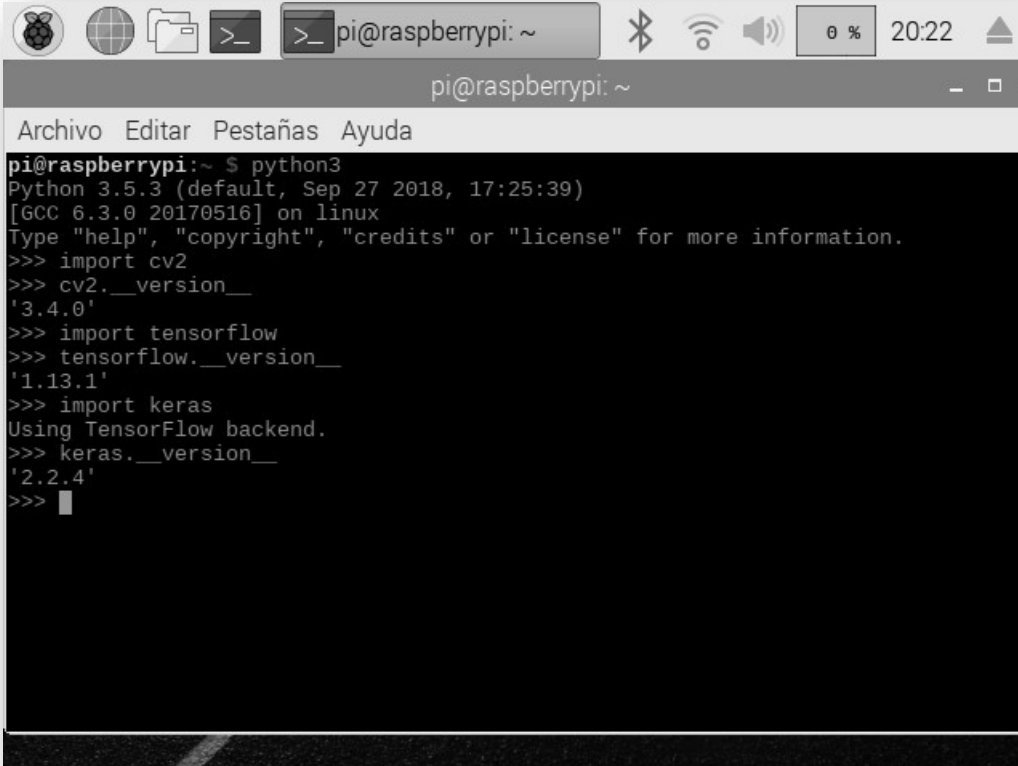
```
sudo apt-get update
```

Finalmente podemos instalar *Keras* usando *pip* dentro de nuestro entorno:

```
pip3 install keras [43]
```

Una vez hechas las instalaciones de las librerías a utilizar es conveniente probar la correcta instalación, una forma de hacerlo es importando dichas librerías; en la Figura 40 muestra la importación de las librerías instaladas.

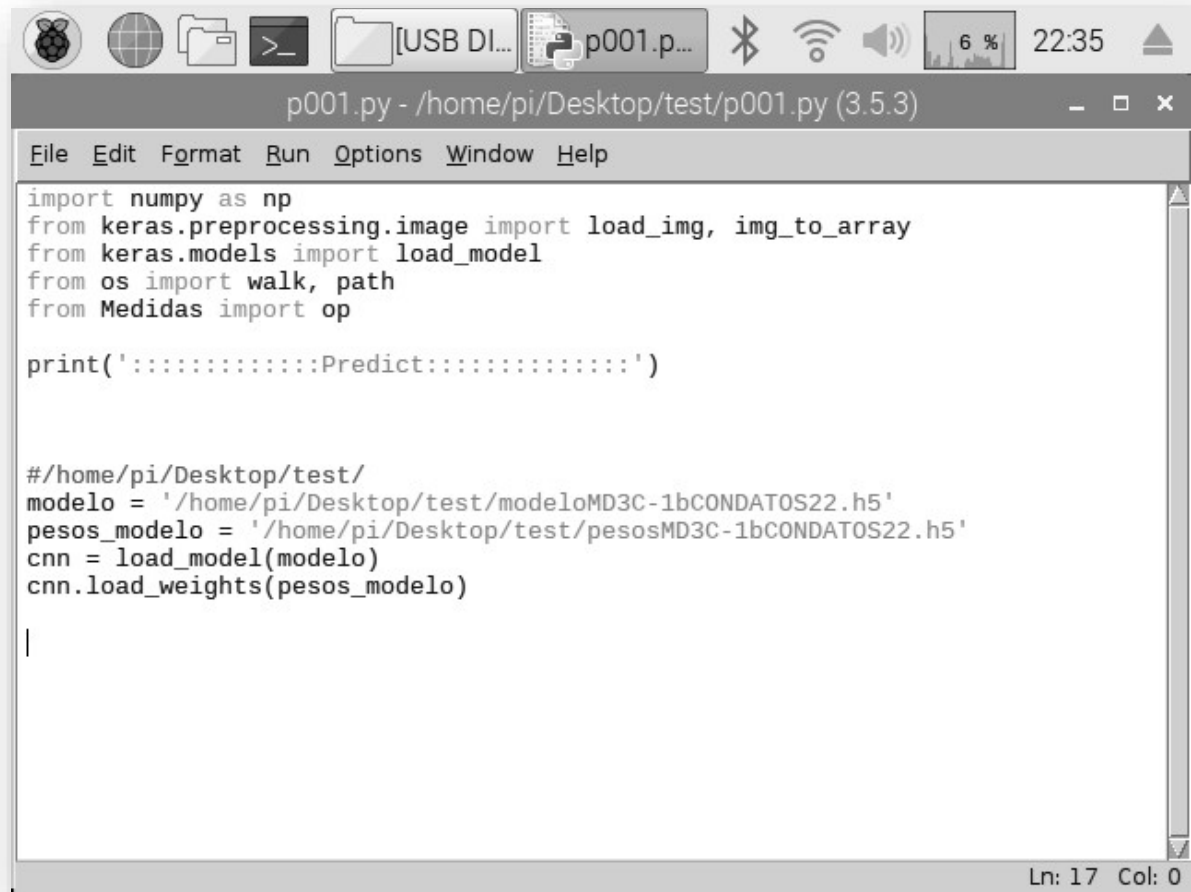
Figura 40 Instalación de opencv, Tensorflow y Keras



```
pi@raspberrypi: ~  
Archivo Editar Pestañas Ayuda  
pi@raspberrypi:~ $ python3  
Python 3.5.3 (default, Sep 27 2018, 17:25:39)  
[GCC 6.3.0 20170516] on linux  
Type "help", "copyright", "credits" or "license" for more information.  
>>> import cv2  
>>> cv2.__version__  
'3.4.0'  
>>> import tensorflow  
>>> tensorflow.__version__  
'1.13.1'  
>>> import keras  
Using TensorFlow backend.  
>>> keras.__version__  
'2.2.4'  
>>> █
```

Después de instalación se pasaron los pesos y los modelos de los resultados del capítulo 4.8, a la *Raspberry Pi 3 Model B*. En la Figura 41 se muestra un fragmento de código de la prueba las librerías instaladas cargando los modelos y pesos antes mencionados.

Figura 41 Prueba de las librerías instaladas para cargar los pesos y modelos.



```
p001.py - /home/pi/Desktop/test/p001.py (3.5.3)
File Edit Format Run Options Window Help
import numpy as np
from keras.preprocessing.image import load_img, img_to_array
from keras.models import load_model
from os import walk, path
from Medidas import op

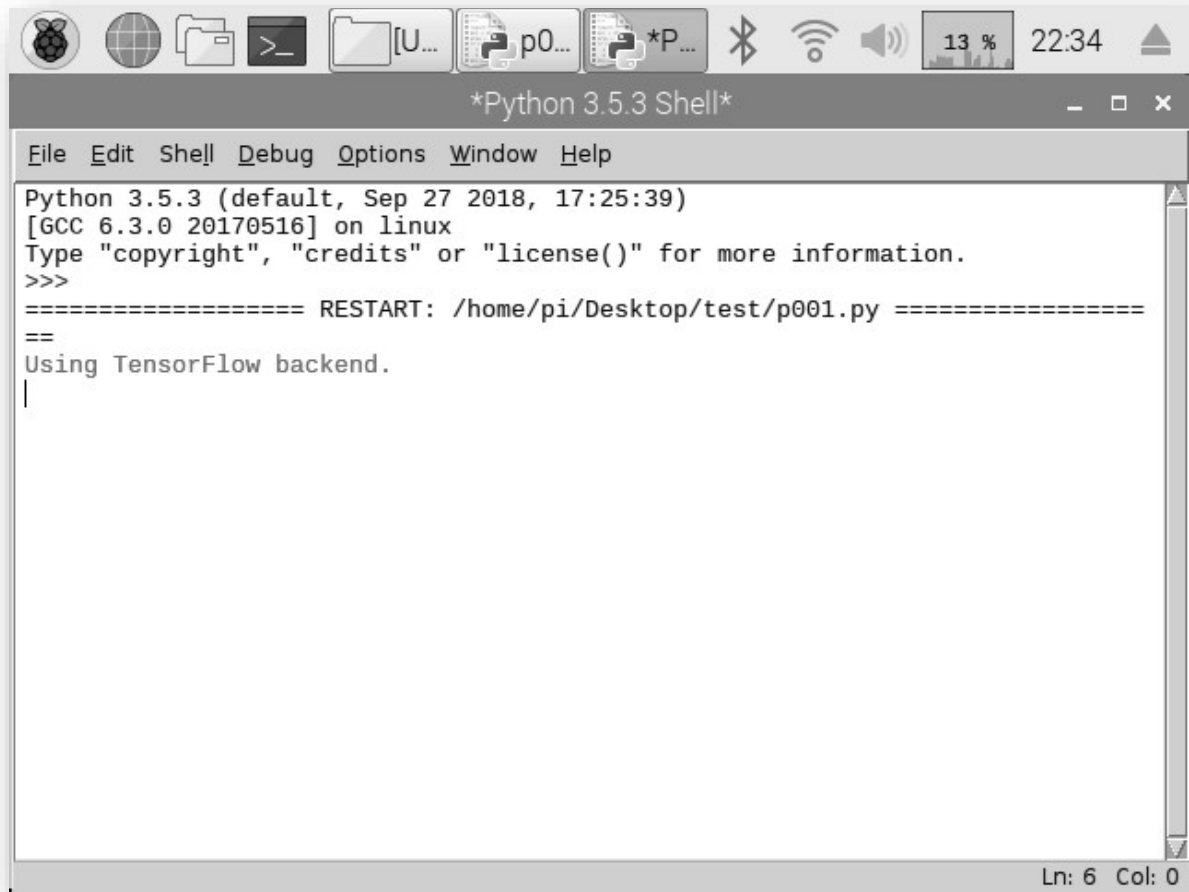
print('::::::::::::Predict::::::::::::')

#/home/pi/Desktop/test/
modelo = '/home/pi/Desktop/test/modeloMD3C-1bCONDATOS22.h5'
pesos_modelo = '/home/pi/Desktop/test/pesosMD3C-1bCONDATOS22.h5'
cnn = load_model(modelo)
cnn.load_weights(pesos_modelo)

|
Ln: 17 Col: 0
```

En la Figura 42 se observa la salida del código de la Figura 41, en la cual se pone en funcionamiento librería de *TensorFlow*.

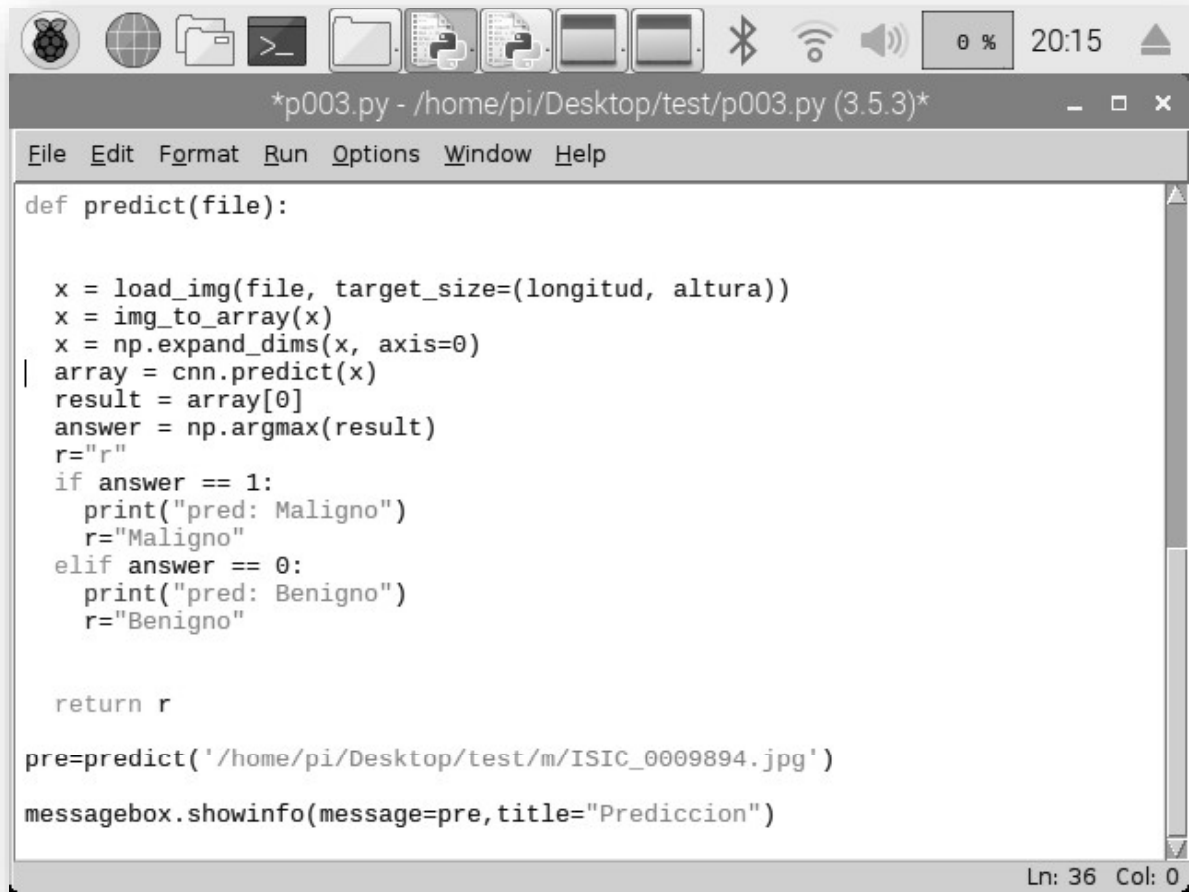
Figura 42 Salida de código de la Figura 41.



```
Python 3.5.3 (default, Sep 27 2018, 17:25:39)
[GCC 6.3.0 20170516] on linux
Type "copyright", "credits" or "license()" for more information.
>>>
===== RESTART: /home/pi/Desktop/test/p001.py =====
==
Using TensorFlow backend.
|
```

Se realizó una predicción de estos con una imagen de melanoma maligna, en la Figura 43 se puede observar un fragmento de código para la predicción.

Figura 43 Fragmento de código de la predicción de melanoma maligno o benigno.



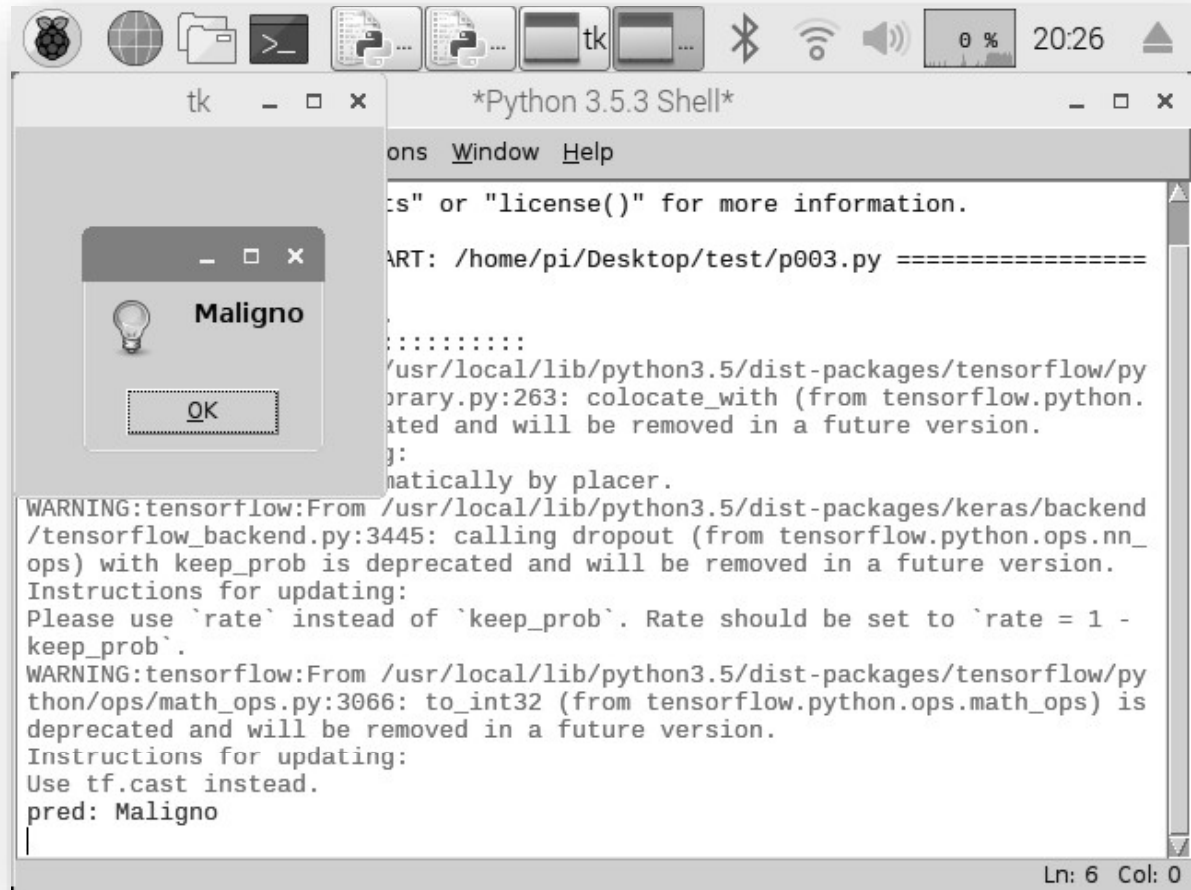
The image shows a screenshot of a Python IDE window titled '\*p003.py - /home/pi/Desktop/test/p003.py (3.5.3)\*'. The window contains the following Python code:

```
def predict(file):  
  
    x = load_img(file, target_size=(longitud, altura))  
    x = img_to_array(x)  
    x = np.expand_dims(x, axis=0)  
    array = cnn.predict(x)  
    result = array[0]  
    answer = np.argmax(result)  
    r=""  
    if answer == 1:  
        print("pred: Maligno")  
        r="Maligno"  
    elif answer == 0:  
        print("pred: Benigno")  
        r="Benigno"  
  
    return r  
  
pre=predict('/home/pi/Desktop/test/m/ISIC_0009894.jpg')  
messagebox.showinfo(message=pre,title="Prediccion")
```

The status bar at the bottom right of the window indicates 'Ln: 36 Col: 0'.

En la Figura 44 se puede observar el resultado de dicha predicción del código de la Figura 43, como se observa el resultado de la predicción es maligno.

Figura 44 Resultado de la predicción de la imagen de un melanoma maligno.

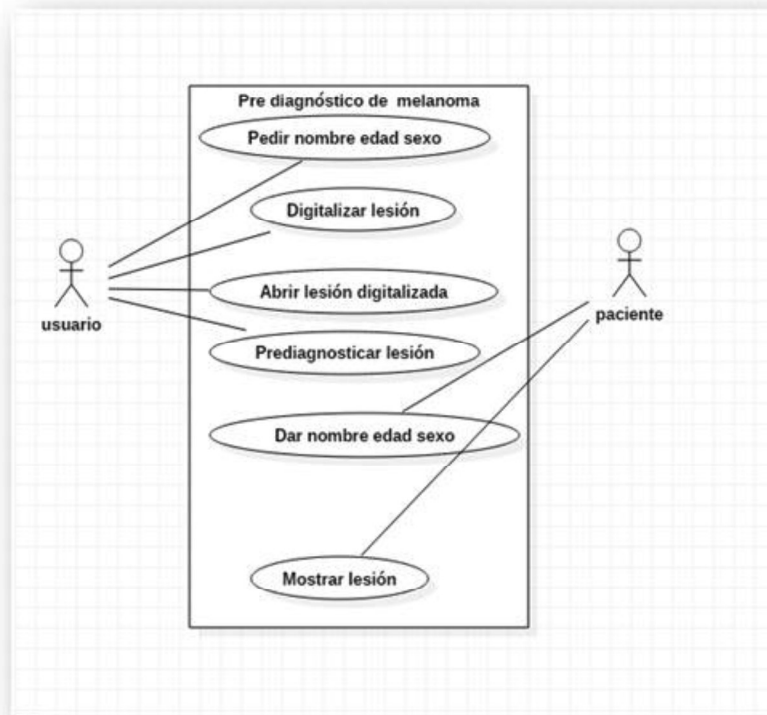


## 5.2 Interfaz del sistema

En la Figura 45 se puede observar el diagrama de casos de uso del sistema propuesto, el usuario del sistema pedirá al paciente su nombre, edad y sexo, digitalizará la lesión del paciente, abrirá esta digitalización en el sistema y por último procederá a hacer un diagnóstico en el sistema.




Figura 45 Diagrama de casos de uso del sistema



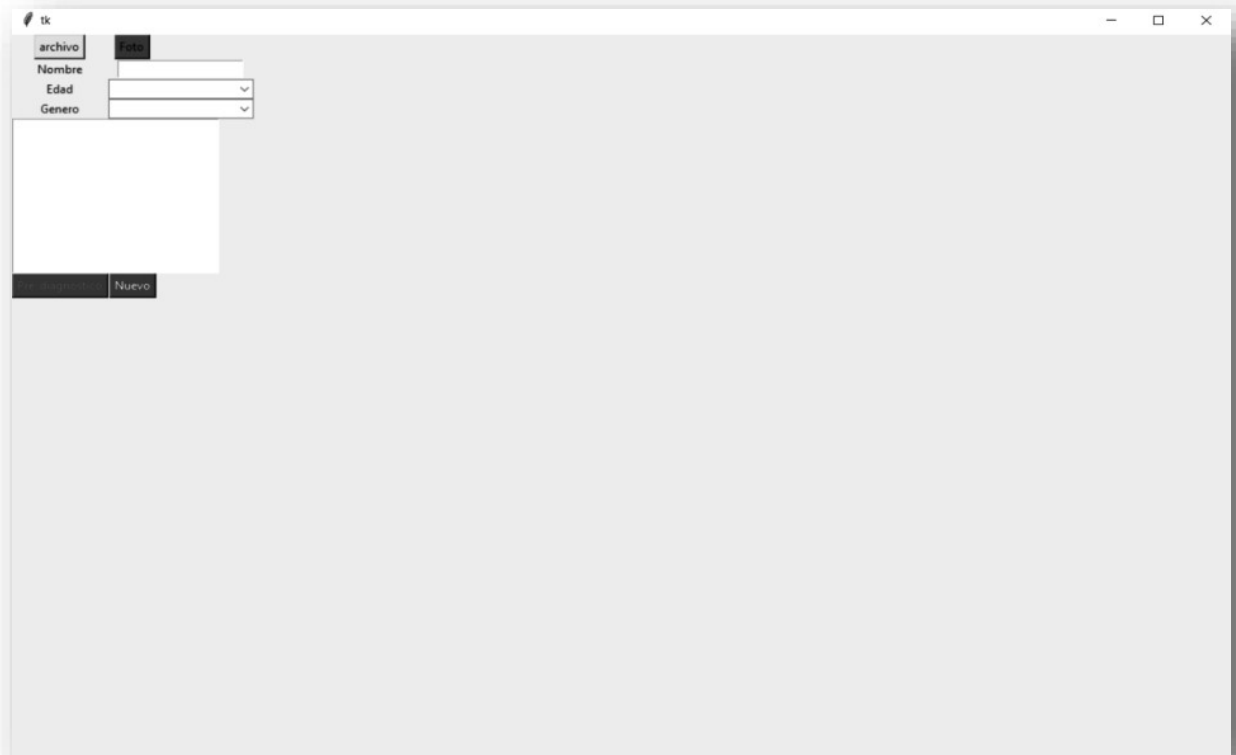
Para abrir el sistema ejecutamos el comando `python3 systema.py`, como se muestra en la Figura 46

Figura 46 Comando para abrir el sistema



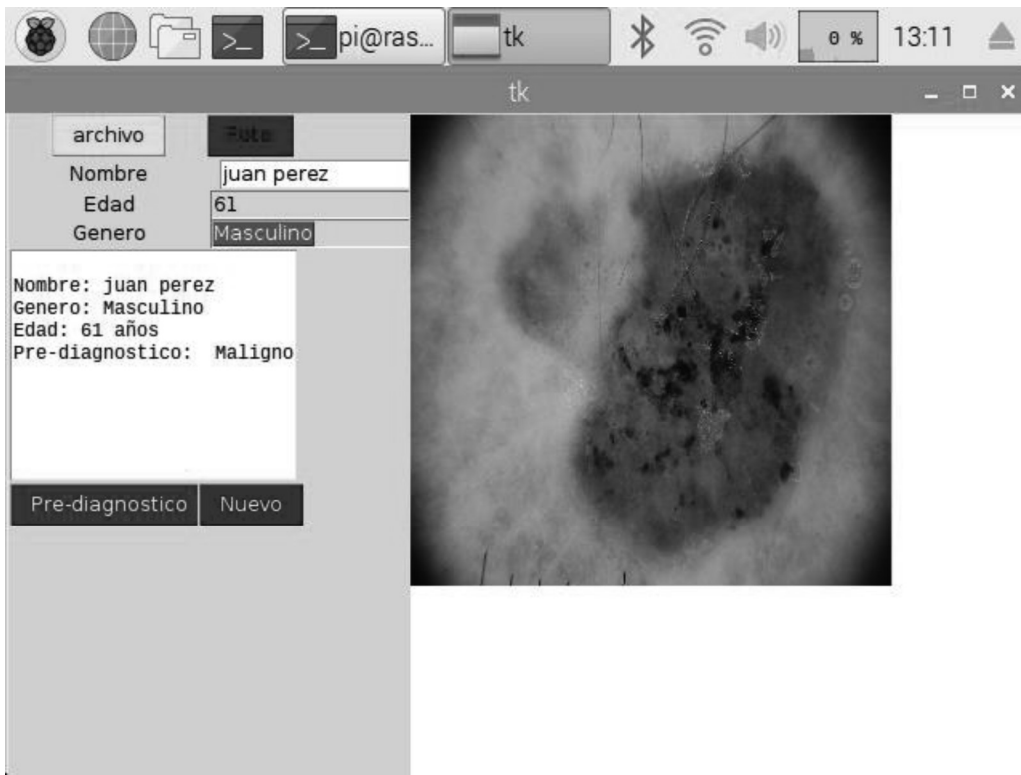
Una vez abierto aparece una interfaz como la que se muestra en la Figura 47, en la cual se observan campos para ingresar el nombre, edad y sexo del paciente, así como el botón “archivo” para abrir una lesión digitalizada, el botón “foto” para digitalizar una lesión, el botón “Pre-diagnóstico” para diagnosticar una lesión digitalizada, y el botón “Nuevo” para hacer un nuevo pre diagnóstico.

Figura 47 Interfaz del sistema



Se capturan los datos generales del paciente, se abrirá la lesión digitalizada del paciente y se procederá a realizar un pre diagnóstico, como se muestra en la Figura 48.

Figura 48 Ejemplo de pre diagnóstico del sistema



## CAPÍTULO 6. TRABAJOS FUTUROS

Como trabajos futuros se ha planteado: usar más imágenes y más épocas para mejorar el 90.00% de precisión, por otro lado, se usarán CNN pre entrenadas con el fin de obtener datos y encontrar la mejor técnica para pensar en un implementación a nivel clínico. Durante el curso de esta investigación, salieron nuevas placas como, Coral, JetsonNano y Raspberry Pi 4, con muchas mejoras en cuanto a memoria y tipo de procesadores, con la cuales se puede aumentar el tamaño de los pesos y modelos generados de una red entrenada. Además, salió la Tensorflow Lite, una librería específicamente implementada para este tipo de placas. También con la Raspberry Pi 4, es posible hacer un clúster con solo 4 (o incluso más) placas de esta computadora para tener una máquina con 16 GB de memoria RAM y más poder de procesamiento y aumentar así el tamaño de los modelos y pesos que se pudieran manejar. Entonces, este proyecto se podría actualizar en tanto software como hardware. También se descubriendo nuevas bases de datos en Internet de melanomas, teniendo así más datos para poder entrenar las CNN. Además, se podría que probar el sistema en un ambiente con fotografías de melanomas tomadas en consultorios médicos reales, para poder ayudar a un diagnóstico oportuno.

## REFERENCIAS

- [1] Pan American Health Organization, «Pan American Health Organization,» 2017. [En línea]. Available: <http://www.paho.org>. [Último acceso: 14 11 2017].
- [2] The Skin Cancer Foundation, «Skin Cancer Foundation,» 2013. [En línea]. Available: <http://www.cancerdepiel.org/cancer-de-piel/melanoma>. [Último acceso: 14 11 2017].
- [3] P. A. ., Q. L. A. Burr Claudia, «Asociación de Salud y Bienestar Social De la Mujer y su Familia,» Mayo 2011. [En línea]. Available: <http://asbis.org.mx/PDF/guiapacienteparticipativo.pdf>. [Último acceso: 01 11 2017].
- [4] G. F. Roldán Rodrigo, «Direccion General de Comunacion Social,» UNAM, 26 05 2016. [En línea]. Available: [http://www.dgcs.unam.mx/boletin/bdboletin/2016\\_362.html](http://www.dgcs.unam.mx/boletin/bdboletin/2016_362.html). [Último acceso: 01 11 2017].
- [5] N. E. A. F. A. Y. Herrea González, «El melanoma en México,» *Revista de Especialidades Médico-Quirúrgicas*, vol. 15, n° 3, pp. 161-164, 2010.
- [6] Q. P. L. C.-d.-M. G. C. T. Quintella Carvalho Danielle, «Histopathological diagnosis of small melanocytic lesions suspicious for,» *An Bras Dermatol*, vol. 3, n° 92, pp. 375-378, 2017.
- [7] A. Mordoh, «Clínica del melanoma,» *Acta Bioquímica Clínica Latinoamericana*, vol. 43, n° 3, pp. 327-331, 2009.
- [8] A. M. P. V. B. A. A. C. José Eduardo Telich Tarriba, «Diagnóstico y tratamiento,» vol. 15, n° 2, pp. 154-160, 2017.
- [9] Y. Q. E. Gladys Bustamante, «MELANOMA OCULAR,» *Revista de Actualización Clínica*, vol. 19, pp. 935-940, 2012.
- [10] B. A. a. C. S. Aurora Sáez, «Pattern Analysis in Dermoscopic Images,» *Computer Vision Techniques for the Diagnosis*, pp. 23-47, 2014.
- [11] M. T. J. M. D. S. M. J. C. M. ANTHONY F. JERANT, «Early Detection and Treatment of Skin,» *American Familt Physician*, pp. 1-17, 2006.
- [12] B. G. Z. Jose Luis García Arroyo, «Automated Detection of Melanoma,» *Computer Vision Techniques for the Diagnosis*, pp. 139-192, 2014.

- [13] U.-O. Dorj, K.-K. Lee, J.-Y. Choi y M. Lee, «Spring Link,» 22 02 2018. [En línea]. Available: <https://link.springer.com/article/10.1007%2Fs11042-018-5714-1>. [Último acceso: 01 03 2019].
- [14] A. Mahbod , R. Ecker y I. Ellinger, «Cornell University,» 17 02 2017. [En línea]. Available: <https://arxiv.org/abs/1702.08434>. [Último acceso: 28 02 2019].
- [15] D. Shoieb A., S. M. Youssef y W. M. Aly, «ResearchGate,» 12 2016. [En línea]. Available: [https://www.researchgate.net/publication/312188377\\_Computer-Aided\\_Model\\_for\\_Skin\\_Diagnosis\\_Using\\_Deep\\_Learning](https://www.researchgate.net/publication/312188377_Computer-Aided_Model_for_Skin_Diagnosis_Using_Deep_Learning). [Último acceso: 01 03 2019].
- [16] A. Bhattacharya, A. Young, A. Wong , S. Stalling , M. Wei y D. Hadley, «NCBI,» 07 2017. [En línea]. Available: <https://www.ncbi.nlm.nih.gov/pubmed/28815132>. [Último acceso: 01 03 2019].
- [17] H. Chang, «Cornell University,» 01 03 2017. [En línea]. Available: <https://arxiv.org/abs/1703.00534>. [Último acceso: 28 02 2019].
- [18] X. Yang, Z. Zen, S. Yeo Yong, C. Tan, H. Tey Liang y Y. Su, «Cornell University,» 03 04 2017. [En línea]. Available: <https://arxiv.org/abs/1703.01025>. [Último acceso: 01 02 2019].
- [19] N. Codella, J. Cai y R. Garnavi, «Springer Link,» 02 11 2015. [En línea]. Available: [https://link.springer.com/chapter/10.1007/978-3-319-24888-2\\_15](https://link.springer.com/chapter/10.1007/978-3-319-24888-2_15). [Último acceso: 01 03 2018].
- [20] H. Liao , «SemanticScholar,» 02 03 2019. [En línea]. Available: <https://www.semanticscholar.org/paper/A-Deep-Learning-Approach-to-Universal-Skin-Disease-Liao/af34fc0aebff011b56ede8f46ca0787cfb1324ac>.
- [21] G. S. V., K. Kottari, K. Delibasis, V. P. Plagianakos y I. Maglogiannis, «Spinger Link,» 11 01 2017. [En línea]. Available: <https://link.springer.com/article/10.1007/s00521-018-3711-y>. [Último acceso: 05 03 2019].
- [22] K. Grzesiak-Kopec, M. Ogorzalek y L. Nowak, «Springer Link,» 29 05 2016. [En línea]. Available: [https://link.springer.com/chapter/10.1007/978-3-319-39384-1\\_15](https://link.springer.com/chapter/10.1007/978-3-319-39384-1_15). [Último acceso: 06 03 2018].
- [23] T. Majtner, S. Yildirim-Yayilgan y J. Yngve Hardeberg1, «Springer Link,» 16 03 2018. [En línea]. Available: <https://link.springer.com/article/10.1007%2Fs11042-018-6734-6>. [Último acceso: 08 03 2019].
- [24] H. A. Haenssle, C. Fink, R. Schneiderbauer, F. Toberer, T. Buhl, A. Blum y A. Kalloo, «ANNALS OF ONCOLOGY,» 28 05 2018. [En línea]. Available:

- <https://academic.oup.com/annonc/article/29/8/1836/5004443>. [Último acceso: 08 03 2019].
- [25] J. Kawahara y H. Ghassan , «Springer Link,» 1 10 2016. [En línea]. Available: [https://link.springer.com/chapter/10.1007/978-3-319-47157-0\\_20](https://link.springer.com/chapter/10.1007/978-3-319-47157-0_20). [Último acceso: 06 03 2019].
- [26] N. Moura, R. Veras, K. Aires, V. Machado, R. Silva, F. Araújo y M. Claro, «Spring Link,» 11 07 2018. [En línea]. Available: <https://link.springer.com/article/10.1007%2Fs11042-018-6404-8>. [Último acceso: 09 03 2019].
- [27] R. Oliveira B., S. A. Pereira y J. M. Tavares S. R., «Spring Link,» 18 03 2018. [En línea]. Available: <https://link.springer.com/article/10.1007/s00521-018-3439-8>. [Último acceso: 09 03 2019].
- [28] J. Premaladha y K. S. Ravichandran , «Springer link,» 12 02 2016. [En línea]. Available: <https://link.springer.com/article/10.1007/s10916-016-0460-2>. [Último acceso: 09 04 2019].
- [29] L. S. Yuexiang Li, Y. Li y L. Shen, «NCBI,» 11 02 2018. [En línea]. Available: <https://www.ncbi.nlm.nih.gov/pubmed/29439500>. [Último acceso: 10 03 2019].
- [30] C. Yu, S. Yang, W. Kim, J. Jung<sup>4</sup>, K.-Y. Chung, S. W. Lee<sup>3</sup> y B. Oh, «Acral melanoma detection using a convolutional neural network for dermoscopy images,» *PLoS ONE*, 2018.
- [31] T. J. Brinker, A. Hekler<sup>1</sup>, J. S. Utikal, N. Grabe, D. Schadendorf, J. Klode, C. Berking<sup>7</sup>, T. Steeb, A. H. Enk y C. v. Kalle, «Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review,» *JOURNAL OF MEDICAL INTERNET RESEARCH*, vol. 10, 2018.
- [32] F. Chollet, Deep Learning with Python, MANNING SHELTER ISLAND, 2018.
- [33] «python,» [En línea]. Available: <https://www.python.org/doc/essays/blurb/>. [Último acceso: 16 03 2019].
- [34] «NumPy,» [En línea]. Available: <http://www.numpy.org/>. [Último acceso: 17 03 2019].
- [35] «OpenCV,» [En línea]. Available: <https://opencv.org/>. [Último acceso: 16 03 2019].
- [36] U. d. C. -. D. d. Física, «youtube,» 2015. [En línea]. Available: <https://www.youtube.com/watch?v=vfYSQIxmybA&t=191s>. [Último acceso: 24 09 2019].



- [37] D. Pedraza, «youtube,» Universidad Nacional de La Plata (UNLP), Argentina., 2 06 2016. [En línea]. Available: <https://www.youtube.com/watch?v=bDvDX70VwEE&t=365s>. [Último acceso: 24 09 2019].
- [38] S. Pattanayak, Pro Deep Learning with TensorFlow A Mathematical Approach to Advanced Artificial Intelligence in Python, India: Apress, 2017.
- [39] S. C. c. CS231n, «CS231n Convolutional Neural Networks for Visual Recognition,» [En línea]. Available: <http://cs231n.github.io/convolutional-networks/>. [Último acceso: 16 06 2019].
- [40] D. Calvo, «<http://www.diegocalvo.es/>,» 7 12 2018. [En línea]. Available: <http://www.diegocalvo.es/funcion-de-activacion-redes-neuronales/>. [Último acceso: 29 11 2017].
- [41] R. Adrian, 18 08 2014. [En línea]. Available: <https://www.pyimagesearch.com/2014/08/18/skin-detection-step-step-example-using-python-opencv/>.
- [42] «ROBOTICA EDUCATIVA Y PERSONAL,» [En línea]. Available: <https://www.robotica.com/Producto/RASPBERRY-PI-3-MODELO-B/>. [Último acceso: 07 09 2019].
- [43] life2coding, «life2coding,» [En línea]. Available: <https://www.life2coding.com/install-opencv-3-4-0-python-3-raspberry-pi-3/>. [Último acceso: 12 12 2018].
- [44] R. Ferro, «DEV,» [En línea]. Available: <https://dev.to/rodolfoferro/setup-your-raspberry-pi-model-b-as-google-colab-feb-19-to-work-with-tensorflow-keras-and-opencv-k6p>. [Último acceso: 13 12 2018].